Catalogue no. 62F0026MIE — No. 006
ISSN: 1708-8879
ISBN: 0-662-41722-4

Research Paper

Household expenditures research paper series

Survey of Household Spending 2003: Data Quality Indicators

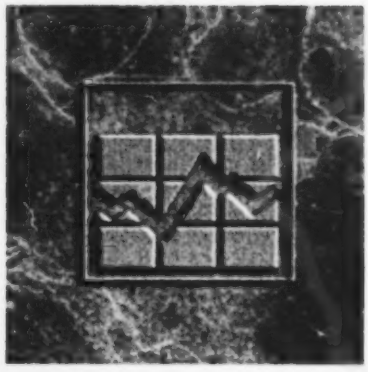

by Yi Li, Charles Mitchell, Sylvain Nadon and Paddison Wong

Household Survey Methods Division
R.H. Coats Building, Ottawa, K1A 0T6

Telephone: 613 951-7355

Statistics Canada Statistique Canada

Canada

How to obtain more information

Specific inquiries about this product and related statistics or services should be directed to: Income Statistics Division, Statistics Canada, Ottawa, Ontario, K1A 0T6 (telephone: (613) 951-7355); (888) 297-7355 income@statcan.ca.

For information on the wide range of data available from Statistics Canada, you can contact us by calling one of our toll-free numbers. You can also contact us by e-mail or by visiting our website.

National inquiries line	1 800 263-1136
National telecommunications device for the hearing impaired	1 800 363-7629
Depository Services Program inquiries	1 800 700-1033
Fax line for Depository Services Program	1 800 889-9734
E-mail inquiries	infostats@statcan.ca
Website	www.statcan.ca

Information to access the product

This product, catalogue no. 62F0026MIE, is available for free. To obtain a single issue, visit our website at www.statcan.ca and select Our Products and Services.

Standards of service to the public

Statistics Canada is committed to serving its clients in a prompt, reliable and courteous manner and in the official language of their choice. To this end, the Agency has developed standards of service that its employees observe in serving its clients. To obtain a copy of these service standards, please contact Statistics Canada toll free at 1 800 263-1136. The service standards are also published on www.statcan.ca under About Statistics Canada > Providing services to Canadians.

Statistics Canada
Income Statistics Division

Household expenditure research paper series

Survey of Household Spending 2003: Data Quality Indicators

Published by authority of the Minister responsible for Statistics Canada

© Minister of Industry, 2005

All rights reserved. The content of this publication may be reproduced, in whole or in part, and by any means, without further permission from Statistics Canada, subject to the following conditions: that it is done solely for the purposes of private study, research, criticism, review, newspaper summary, and/or for non-commercial purposes; and that Statistics Canada be fully acknowledged as follows: Source (or "Adapted from", if appropriate): Statistics Canada, name of product, catalogue, volume and issue numbers, reference period and page(s). Otherwise, no part of this publication may be reproduced, stored in a retrieval system or transmitted in any form or by any means, electronic, mechanical, photocopy, for any purposes, without the prior written permission of Licensing Services, Marketing Division, Statistics Canada, Ottawa, Ontario, Canada K1A 0T6.

October 2005

Catalogue no. 62F0026MIE2005006

ISSN: 1708-8879
ISBN: 0-662-41722-4

Frequency: Occasional

Ottawa

La version française de cette publication est disponible sur demande (nº 62F0026MIF au catalogue).

Note of appreciation

Canada owes the success of its statistical system to a long-standing partnership between Statistics Canada, the citizens of Canada, its businesses, governments and other institutions. Accurate and timely statistical information could not be produced without their continued cooperation and goodwill.

This report was prepared by the members of the Survey of Household Spending unit of the Household Survey Methods Division (HSMD):

Yi Li
Charles Mitchell
Sylvain Nadon
Paddison Wong

The authors wish to thank the team responsible for the Survey of Household Spending in the Income Statistics Division (ISD) for their co-operation in the preparation of this report.

Table of contents

Highlights **6**

Introduction **9**

1. Sampling errors **10**

1.1 Measures of sampling error 10
1.2 Coefficients of variation 10
1.3 Model for deriving an approximation of the CV 13
1.4 Suppression of unreliable data in estimation tables 14

2. Nonresponse **15**

2.1 Response, nonresponse and vacancy rates 15
2.2 Nonresponse according to urbanization level 18
2.3 Nonresponse according to income strata 19
2.4 Adjustment for nonresponse 20

3. Coverage errors **20**

3.1 Undercoverage and overcoverage: slippage rates 21
3.2 Adjustment at the population and household levels 25

4. Response errors **26**

5. Processing errors **28**

5.1 Proportion of households or persons requiring imputation at national, provincial and territorial levels 29

References **35**

Appendix A Algebraic notation **36**

Highlights

Sampling errors

- The coefficients of variation (CVs) of the average estimates of total expenditure per household vary between 1.2% and 2.3% for the provinces. The CV at the national level is 0.7%. The CVs are higher in the territories, namely 3.6% in the Yukon, 3.9% in the Northwest Territories and 5.9% in Nunavut.

- The coefficients of variation (CVs) of the average estimates for the different summary level expenditure categories are in most cases less than or equal to 1.7% at the national level, and generally lower than 5.0% at the provincial level. The results for the characteristics of dwelling and household equipment are similar. The sample size being smaller in the territories, the CVs tend to be higher than those of the provinces.

Nonresponse

- The final response rate is 72.3%. Provincial and territorial response rates range from 62.8% for Ontario to 91.6% in Nunavut.

- The nonresponse rate is 27.7%. It is due to refusals (17.7%), to households that could not be contacted (6.9%), and finally to households with data that were considered unusable (3.0%).

- The final nonresponse rate generally increases with the urbanization level. The nonresponse rate is 22.3% at the rural level, and 33.8% in the urban centres of one million residents or more. This tendency is also observed in the collection nonresponse rates.

- Analysis of final response rates in the strata consisting of high and low-income geographic areas created under the sample design indicates that the nonresponse rate in high-income strata (42.2%) is higher than the rates observed in regular strata (27.3%) and in low-income strata (27.3%). The refusal rate for high-income strata (30.5%) is more than twice the rate of low-income strata (13.3%) and nearly twice the rate of regular strata (17.4%).

Coverage errors

- There is undercoverage of 8.5% for households at the national level. Undercoverage of households is also observed for all provinces and territories, with rates varying from 4.9% to 14.9%. Yukon and British Columbia have the highest undercoverage of households.

- There is undercoverage of 11.3% for persons at the national level. Undercoverage of persons is also observed for all provinces and territories, with rates varying from 6.6% to 22.7%. Yukon and the Northwest Territories have the highest undercoverage of persons.

- At the national level, there is always a net undercoverage for each age group. Except for the category 65 to 69 years old, the undercoverage rates for children (0 to 6 and 7 to 17) are smaller than those of the adults. The undercoverage rate for all children combined is 5.5%, while it is 13.0% for adults.

Response errors

- Response errors include, among others, recall errors, telescopic error and errors due to proxy response. Because the Survey of Household Spending (SHS) interview is lengthy, the response burden can lead to respondent fatigue and have an impact on the data quality. Total interview time varies according to the household characteristics. For some households the interview can take more than five hours. The average length of interview was one hour and forty-six minutes.

Processing errors related to imputation

i) Expenditure variables

- For 12.8% of households, it was necessary to impute at least one expenditure variable (excluding the Clothing section and Personal Taxes, Security and Money Gifts section). For the majority of them, only one or two out of the 229 expenditure variables were imputed. Provincially and territorially, the imputation rates range from a low of 6.6% for Quebec to a high of 18.2% in Newfoundland and Labrador. The overall imputation rate is 8.3% when excluding regular mortgage payments and mortgage insurance premiums, which is similar to rates obtained in previous years. There are 15.6% of households reporting mortgages on owned and occupied dwellings that need an imputation for the mortgage insurance premiums.

- About 19% of the individuals required imputation for clothing variables. For the majority of these, the respondents provided the totals and only the components were imputed.

- About 3% of the individuals aged 15 years old and over required imputation on at least one variable in the Personal Taxes, Security and Money Gifts section.

ii) Income variables

- Less than 5% of individuals aged 15 years and over required imputation for at least one income variable. For 70% of them, total income was provided by the respondent and imputation was performed to obtain the breakdown by components.

iii) Categorical variables

- For 6.4% of households, it was necessary to impute at least one categorical variable. Nearly 75% of them had only one variable imputed. At the provincial or territorial level, the imputation rates range from a low of 2.8% in Prince

Edward Island to a high of 10.7% in Saskatchewan. Categorical variables that required imputation can be found in the following sections of the questionnaire: Dwelling Characteristics; Facilities Associated with the Dwelling; Tenure; Tobacco and Miscellaneous for variables pertaining to purchases through direct sales.

Introduction

The Survey of Household Spending (SHS) is an annual survey that collects data on household income and expenditure using personal interviews. The 2003 SHS sample is made up of 23,869 households[1] distributed throughout the 10 provinces and the 3 territories. Collection takes place in January, February and March, and income and spending figures are obtained for the period from January 1 to December 31 of the previous year. Following a redesign that took place in 1997, this survey replaces the periodic Family Expenditure Survey and the Household Facilities and Equipment Survey (with modifications to questionnaires and samples).

Like all surveys, the SHS is subject to errors, despite all the precautions taken at the different stages of the survey to control them. While there is no comprehensive measure of the quality of the data generated by a survey, some quality measures produced at the different stages of the survey can provide users with the information needed in order to interpret the data properly.

This report therefore seeks to describe the quality indicators produced for the 2003 Survey of Household Spending. It covers the usual quality indicators that generally help users interpret data, such as coefficients of variation, response and nonresponse rates, slippage rates and imputation rates.

Quality indicators have been classified according to the main types of error encountered in a survey. Section 1 deals with sampling errors—that is, errors due to the fact that the inferences about the population drawn from the survey are based on information collected from a sample of the population, rather than the entire population. The subsequent sections cover errors not due to sampling. Nonresponse and coverage errors are first discussed in sections 2 and 3. Response errors and processing errors are dealt with in sections 4 and 5 respectively.

This report focuses on data quality. For a detailed description of the methodology of the survey, see reference [1].

1. The initial sample is made up of 27,671 dwellings. From these dwellings, we have to identify and exclude the ineligible dwellings (see section 2.1) to obtain the 23,869 households from which we collect data on household income and expenditure.

1. Sampling errors

Sampling errors exist when inferences about the population are drawn from the survey using information collected from a sample, rather than the entire population. In addition to the sample design and the estimation method used in the Survey of Household Spending, the sample size and the variability of each characteristic are factors that determine sampling error. Characteristics that are rare or are distributed very unevenly in the population will have greater sampling error than characteristics that are observed more frequently or are more homogeneous in the population.

1.1 Measures of sampling error

Standard error is a commonly used measure of sampling error. Standard error is the degree of variation of the estimate considering that a particular sample was selected, rather than another, among all possible samples of the same size under the same sample design. Since the SHS uses a complex sample design and estimation method, the standard error is estimated using a resampling method known as the bootstrap technique. Prior to 2003 reference year, the jackknife resampling method was used to produce standard error estimation for SHS. Starting with the 2003 SHS, a decision was made to use the bootstrap resampling method mainly because the Income Statistics Division was going to publish the median expenditures estimates and needed the coefficient of variation of those estimates. The bootstrap resampling method is suitable for variance estimation of non-smooth statistics such as quantiles. For more details on this method, see reference [2].

Coefficient of variation (CV) is also a frequently used measure of the reliability of an estimate. It simply expresses the standard error as a percentage of the estimate. Thus, if an estimate Y is obtained for a certain characteristic and SE is the estimated standard error, then the CV will be (SE/Y) x 100.

Finally, either the standard error or the coefficient of variation may be used to derive another measure of the accuracy of estimates, namely the confidence interval. This measure indicates the level of confidence that, for a characteristic observed, the true value for the population lies within the interval. An interval with a confidence level of 95% corresponds to the estimate obtained from the sample $\pm$ 2 standard errors: (Y $\pm$ 2 SE).[2] This means that if the sampling were repeated a large number of times, each sample would provide a different interval and 95% of the intervals would contain the true value of the characteristic. Similarly, if the sampling were repeated, the interval Y $\pm$ SE would contain the true value in 68% of cases.

1.2 Coefficients of variation

Estimates of coefficients of variation are calculated for estimates of many characteristics collected in the SHS. The CVs of detailed average household

2. The confidence interval is calculated directly from the CV in similar fashion, namely Y $\pm$ 2 (CV x Y)/100.

expenditure, as well as the CVs of dwelling characteristics and household facilities and equipment, are available at the national, provincial and territorial levels in the publication *User Guide—Survey of Household Spending* (see reference [3]).

It should be noted that the estimated CVs do not consider the fact that some of the data were imputed and thus may underestimate the true CVs. For most variables, the imputation rates are low (see Section 5) and the provided CVs represent good estimates. To assess the reliability of detailed expenditure with a high imputation rate, the CV and the imputation rate should be considered simultaneously.

Table 1.1 gives an overview of the CVs of estimates of household averages for a few of the summary-level expenditure categories and for income at the provincial, territorial and national levels.

Table 1.1
Coefficients of variation (%) by province, territory and at the national level for the estimation of average household expenditures for several summary level expenditure categories and for the estimation of average income

Summary level expenditure categories	Can.	N.L.	P.E.I.	N.S.	N.B.	Que.	Ont.	Man.	Sask.	Alta.	B.C.	Y.T.	N.W.T.	Nvt.
Total expenditure	0.7	1.6	2.3	1.6	1.2	1.7	1.4	1.4	1.5	1.3	1.5	3.6	3.9	5.9
Total current consumption	0.7	1.5	2.2	1.4	1.3	1.3	1.3	1.5	1.5	1.4	1.4	3.4	3.9	5.8
Food	0.6	1.3	2.2	1.3	1.3	0.9	1.2	1.5	1.6	1.4	1.4	3.8	3.5	2.9
Shelter	0.9	2.3	2.7	1.6	1.8	1.4	1.7	2.1	1.5	1.9	1.6	4.1	5.1	7.2
Household operation	1.0	1.6	3.5	2.6	2.0	1.6	2.1	1.9	1.9	2.3	2.1	4.7	4.1	7.1
Furnishings	1.7	3.5	5.5	4.1	3.4	3.4	3.3	3.8	4.3	3.5	4.2	10.5	9.2	12.4
Clothing	1.3	2.5	3.5	3.0	2.7	2.0	2.5	2.5	3.1	2.8	3.4	10.1	6.5	8.2
Transportation	1.5	3.7	4.7	3.6	3.0	3.3	2.8	4.6	3.7	3.7	3.3	7.2	10.4	19.7
Health care	1.3	3.0	3.5	3.7	3.2	2.0	3.3	4.0	3.8	2.5	2.8	7.8	9.9	19.7
Personal care	1.0	2.2	3.6	2.1	2.4	1.6	2.0	2.2	2.2	2.8	2.5	9.9	4.6	8.2
Recreation	1.7	3.8	6.5	3.1	4.5	3.0	3.4	3.5	3.7	3.3	3.9	7.7	7.3	9.2
Reading & printed materials	1.7	4.3	5.1	3.8	4.0	2.9	3.6	4.0	3.3	4.1	3.7	7.6	8.0	19.0
Education	3.0	7.5	11.0	8.3	8.6	4.3	5.4	7.5	6.9	7.3	6.7	12.4	19.6	29.7
Tobacco, alcoholic	1.6	3.6	6.9	4.1	4.8	2.7	3.5	4.8	4.0	4.5	4.5	8.4	8.2	8.1
Games of chance (net)	4.1	6.4	13.8	8.0	9.6	6.3	7.7	8.2	7.4	13.3	13.4	14.4	24.3	20.4
Miscellaneous expenditures	2.9	6.0	28.1	5.1	5.4	4.2	6.0	6.0	6.4	8.2	6.5	10.9	7.6	17.2
Personal income tax	1.7	3.7	4.5	2.8	2.2	3.4	3.2	2.6	2.9	2.5	2.6	6.3	5.2	9.7
Personal insurance and pension contributions	1.2	3.1	2.9	9.5	1.9	2.5	2.3	3.2	2.2	2.1	2.0	6.9	5.0	6.7
Gifts and contributions	6.0	8.3	14.9	9.3	7.9	9.3	10.8	11.5	6.3	7.6	18.6	15.1	15.1	16.5
Income	0.7	1.4	2.2	1.5	1.1	1.6	1.5	1.3	1.5	1.1	1.4	3.9	4.6	6.0

The coefficients of variation (CVs) of the average estimates of total expenditure per household vary between 1.2% and 2.3% for the provinces. The CVs are higher in the territories, namely 3.6% in the Yukon, 3.9% in the Northwest Territories and 5.9% in Nunavut. The CV at the national level is 0.7%.

For summary-level expenditure categories, the CVs at the national level are less than or equal to 1.7%, except for the following categories: education, games of chance, miscellaneous expenditures and gifts of money and contributions. These expenditure categories represent respectively 1.6%, 0.4%, 1.5% and 2.5% of total expenditure (data not shown). Also, with the exception of these categories, the CVs are generally less than or equal to 5% at the provincial level. With the exception of the same above-mentioned categories, the CVs in the territories are mostly less than 11%. Moreover, the sample size being smaller in the territories, the CVs tend to be higher than those of the provinces.

Table 1.2 gives an overview of the CVs for some dwelling characteristics and household equipment estimates at the provincial and territorial level as well as at the national level.

Table 1.2
Coefficients of variation (%) by province, territory and at the national level for some dwelling characteristics and household equipment

Categories	Can.	N.L.	P.E.I.	N.S.	N.B.	Que.	Ont.	Man.	Sask.	Alta.	B.C.	Y.T.	N.W.T.	Nvt.
Owner	0.9	1.7	3.3	2.0	1.8	1.7	1.9	1.9	1.8	1.9	1.9	6.6	10.9	15.1
Renter	1.7	5.6	8.6	5.0	5.2	2.2	4.0	4.7	5.0	4.8	3.3	10.8	16.4	8.5
Washing machine	0.6	0.9	2.1	1.5	1.3	0.8	1.5	1.6	1.2	1.1	1.3	4.7	5.3	4.9
Clothes dryer	0.6	1.1	2.3	1.5	1.3	0.9	1.6	1.6	1.1	1.2	1.5	4.4	7.0	5.5
Dishwasher	1.1	3.8	4.7	3.5	3.4	1.9	2.5	2.7	2.6	2.0	1.8	7.2	8.0	12.4
Freezer	1.0	1.4	3.0	2.3	1.8	2.0	2.1	1.7	1.5	2.3	2.2	5.6	6.1	7.9
Microwave oven	0.3	0.6	1.1	0.7	0.6	0.6	0.6	0.7	0.6	0.6	1.0	2.1	4.3	4.7
Cellular phone	1.1	2.9	5.2	2.8	3.7	2.4	2.0	2.8	2.8	2.0	2.1	12.2	8.0	24.6
CD player	0.6	1.5	2.5	1.5	1.7	1.2	1.3	1.7	1.6	1.3	1.4	4.4	3.5	6.0
Cable TV	1.0	2.4	5.0	2.7	2.9	1.9	2.0	2.7	3.0	2.6	1.6	10.4	6.2	6.8
Satellite dish	2.4	5.0	7.8	5.6	5.0	4.2	5.5	4.7	4.4	4.8	5.7	11.7	12.0	16.4
DVD player	1.1	2.9	4.7	2.4	2.9	2.1	2.2	2.3	2.6	2.1	2.6	5.4	5.0	8.2
Home computer	0.8	2.5	3.8	2.0	2.4	1.6	1.5	2.0	1.8	1.6	1.6	4.8	6.8	7.9
Regular tel. connection to a computer (Modem)	2.4	5.4	9.5	6.2	4.6	4.1	4.4	7.0	7.1	7.4	6.8	15.3	17.4	11.2
High-Speed tel. connection to a computer	2.7	9.4	12.0	5.6	8.5	5.1	5.7	6.7	5.2	5.3	5.5	9.2	12.8	40.0
Use of internet (home)	0.9	3.2	4.9	2.4	2.8	2.0	1.9	2.7	2.4	2.1	2.1	6.7	7.0	10.8
Owned vehicles (one)	1.3	2.8	6.2	3.7	3.4	2.4	2.9	3.1	3.3	3.1	2.9	9.6	5.6	14.3
Owned vehicles (2 or more)	1.4	4.4	4.9	2.9	3.5	2.9	3.1	2.8	3.2	2.4	2.7	7.1	10.2	22.3

The coefficients of variation for the estimates of dwelling characteristics and household equipment are generally below 5% at the provincial level, with some exceptions in the following categories: rent, satellite dish, regular telephone connection to a computer (modem) and high-speed telephone connection to a computer. The CVs are higher in the territories where we can find a smaller proportion of equipment. In addition, the sample size being smaller in the territories, the CVs tend to be higher than those of the provinces.

The coefficients of variation for dwelling characteristics and household equipment at the national level are below or equal to 1.7% with the exception of the following categories: satellite dish, regular telephone connection to a computer (modem) and high-speed telephone connection to a computer. There is a smaller proportion of households with such equipment for these three categories. At the national level, this proportion represents 22.6%, 21.2% and 17.3% respectively (data not shown).

1.3 Model for deriving an approximation of the CV

Estimates for different domains of interest (for example, by income quintile) for the summary level expenditure categories are available in the publication *Spending Patterns in Canada* (see reference [4]). Estimates for different domains of interest for detailed expenditures are available upon request from the Income Statistics Division. (For more details on tables available upon request from the Income Statistics Division, see references [3] or [4].) For operational reasons, it is not possible to produce CVs for all the characteristics collected by the survey at all the different levels of aggregation that may interest users.

1.3.1 Model for deriving an approximation of the CV for domain estimates

It is, however, possible to calculate an approximation of the CV by using a relationship between the number of households in the sample that reported expenditures for a given category and the CV at an aggregated level. This relationship, based on the CV's tendency to increase in proportion to a decrease in the square root of the number of households reporting an expenditure, is illustrated below.

Formula for approximating the CV for a domain (subgroup of the population)

If CV(Y) represents the CV for the estimate of the average per household of a certain characteristic for the entire population, then an approximation of the CV of the estimate of that characteristic can be calculated for a domain (which may be considered as a subgroup of the population, such as household type, income quintile, urbanization level) according to the following equation:

$$CV(Y_d) = CV(Y) \times \sqrt{\frac{nP}{n_d P_d}}$$

where

n: number of households in the sample
P: estimate of the proportion of households reporting a value > 0 for this characteristic in the population
n_d: number of households in the sample in domain d
P_d: estimate of the proportion of households reporting a value > 0 for this characteristic in domain d

Generally, approximations for the different domains are calculated using the CV, size n and proportion P at the national level. If an approximation of a CV is desired for a domain that is entirely contained within a single province (for example, a metropolitan area), then it is preferable to use the values at the provincial level, since provincial CVs are published for the 2003 SHS (reference [3]). It should be noted that a CV obtained using this approach is only an approximation of the real value.

1.3.2 Method of computation of an approximate CV from the microdata file

The microdata file users can obtain an approximation of the CV of the estimates using another method which will generally provide better results than the method described in the previous section for the CVs of detailed expenditure estimates. This approach is described in detail in the documentation provided with the 2003 microdata file. This method of approximation can be used only with the microdata file since it is necessary to have data and weights for each household.

The document on data quality for the 1997 SHS contains the results from the performance evaluation of these two CV approximation methods.

1.4 Suppression of unreliable data in estimation tables

Since the coefficient of variation is an indicator of the reliability of data, we would like to use it to determine whether or not the estimates should be published. Estimates for which the CV is more than 33% are not considered sufficiently reliable to be published. However, CV estimates are not calculated for many of the published estimates. The suppression rule for expenditure estimates is therefore based on the number of households reporting a value greater than zero.[3]

It can be shown that CVs are usually below 33% when the number of households reporting an expenditure is greater than 30. Since this is an approximate rule, some estimates may be published even though the CV is greater than 33%, and some estimates will not be published even though the CV is less than 33%. The document on data quality for the 1997 SHS gives the results from the evaluation of the risk of error in the use of the suppression rule.

3. In practice, we use the estimate of the proportion of households reporting an expenditure, which is multiplied by the sample size.

2. Nonresponse

Errors due to nonresponse result from the fact that some potential respondents do not provide the necessary information or the provided information proves to be unusable. When the respondent has failed to respond to only some questions, this is referred to as partial nonresponse. In such a case, the missing data are imputed. Errors associated with imputation are described in Section 5, which deals with processing errors. In the present section, nonresponse includes collection nonresponse, which is mainly due to the inability to contact the household or to the refusal of the members of the household to participate partially or completely in the survey, as well as data collected from households that prove to be unusable.

The main impact of nonresponse on data quality is that it can introduce a bias in the estimates if the characteristics of respondents and nonrespondents differ and the difference has an impact on the characteristics studied. Nonresponse rates may easily be calculated, but they have only an indicative value with regard to data quality, since they do not allow estimation of the bias associated with the estimates. The scope of nonresponse may be considered as an indicator of the risks of bias in the estimates.

2.1 Response, nonresponse and vacancy rates

Since the units selected in the SHS are dwellings, interviewers must first identify ineligible dwellings, that is, dwellings occupied by persons who are not part of the target population, as well as dwellings that no longer exist (demolished, mobile home moved or dwelling converted to business) and vacant dwellings (unoccupied, seasonal or under construction).

Among eligible dwellings, the proportion of households that did not respond to the survey is evaluated next. This is called the collection nonresponse rate. Included are households that refused to participate in the survey and households where no contact could be made with the respondents, either because they were absent or because of special circumstances (language problem, illness, death).

Again among eligible dwellings, the rate of unusable data is determined. Unusable data refers to the number of households whose questionnaires were at least partially completed but which were rejected during data processing. There are two main causes for rejection. First, when many questions on income or expenditures have been left unanswered, the questionnaire is classified as incomplete and is not used. The other source of rejection consists of questionnaires in which the difference between receipts (income and other sources of money received by the household) and disbursements (expenditures and net change in assets and liabilities) is greater than 20%. These questionnaires are also excluded from the estimation and are considered as nonresponse.

Note that all rates provided in this section are unweighted. For the 2003 Survey of Household Spending, the final response rate is 72.3%. Table 2.1a shows the final response rates as well as the sample size (eligible households) broken

down by refusals, no-contacts, usable and unusable data. These rates are provided at the national level as well as at the provincial and territorial level.

This year, a supplementary sample of about 2,000 households in Quebec was financed by the "Ministère des finances du Québec" to better suit their analytic needs. The sample was selected from a list frame of dwellings according to a two-stage stratified sample design. The sampling frame constructed from Statistics Canada's Address Register is comprised of dwellings from selected Dissemination Areas of the 2001 Census. For a detailed description of the sample design of the supplementary sample, see reference [6].

Table 2.1a
Sample size and response rate (%) by province, territory and at the national level

Province or territory	Eligible households	Non-contacts	Refusals	Unusables	Usables	Final response rate (at estimation stage)[1] %
Canada	23,869	1,647	4,234	723	17,265	72.3
Newfoundland and Labrador	1,772	134	198	69	1,371	77.4
Prince Edward Island	781	52	121	27	581	74.4
Nova Scotia	2,048	150	347	132	1,419	69.3
New Brunswick	1,845	98	303	118	1,326	71.9
Quebec	4,817	360	927	68	3,462	71.9
Ontario	3,149	282	787	103	1,977	62.8
Manitoba	1,887	104	312	49	1,422	75.4
Saskatchewan	1,837	72	280	77	1,408	76.6
Alberta	2,087	128	336	18	1,605	76.9
British Columbia	2,58	205	500	45	1,83	70.9
Yukon	418	28	74	9	307	73.4
Northwest Territories	410	21	42	8	339	82.7
Nunavut	238	13	7	-	218	91.6

1. Usable/eligible x 100

Table 2.1b shows the final nonresponse rates; the collection nonresponse rates, broken down by refusals and no-contacts; and the rate of unusable data broken down into incomplete and out-of-balance questionnaires. The vacancy rate is also included. These rates are provided at the national level as well as at the provincial and territorial level.

Note that the vacancy rates shown in tables of Section 2 include vacant dwellings (unoccupied, seasonal or under construction) as well as dwellings that no longer exist (demolished, mobile home moved or dwelling converted to business).

Table 2.1b
Nonresponse and vacancy rates (%) by province, territory and at the national level

Province or territory	Vacancy rate	Collection nonresponse rate			Unusable data rate			Final nonresponse rate (at estimation stage)
		Total	No contact	Refusal	Total	Incomplete	Out-of-balance	
Canada	11.0	24.6	6.9	17.7	3.0	1.3	1.7	27.7
Newfoundland and Labrador	15.4	18.7	7.6	11.2	3.9	1.8	2.1	22.6
Prince Edward Island	18.1	22.2	6.7	15.5	3.5	1.7	1.8	25.6
Nova Scotia	13.8	24.3	7.3	16.9	6.4	1.2	5.2	30.7
New Brunswick	13.7	21.7	5.3	16.4	6.4	1.9	4.5	28.1
Quebec	7.3	26.7	7.5	19.2	1.4	1.2	0.2	28.1
Ontario	8.2	33.9	9.0	25.0	3.3	1.9	1.4	37.2
Manitoba	9.6	22.0	5.5	16.5	2.6	0.7	1.9	24.6
Saskatchewan	15.7	19.2	3.9	15.2	4.2	1.3	2.9	23.4
Alberta	9.0	22.2	6.1	16.1	0.9	0.7	0.1	23.1
British Columbia	8.9	27.3	7.9	19.4	1.7	1.4	0.4	29.1
Yukon	15.3	24.4	6.7	17.7	2.2	0.2	1.9	26.6
Northwest Territories	12.2	15.4	5.1	10.2	2.0	0.2	1.7	17.3
Nunavut	14.8	8.4	5.5	2.9	0.0	0.0	0.0	8.4

The final nonresponse rate at the national level is 27.7%. It is due to refusals (17.7%), to households that could not be contacted (6.9%), and finally to households for which the data were unusable (3.0%). For most provinces, refusals are the main cause of nonresponse, followed by the households that could not be contacted, and by the households for which the data were unusable. The only exceptions are Nunavut for whom the refusal rate is smaller than the no-contact rate, as well as New Brunswick and Saskatchewan where the proportion of unusable data is higher than the proportion of households that we were unable to contact.

The final nonresponse rate varies from one province to another. Nunavut has the lowest nonresponse rate at 8.4%. The lowest refusal rate (2.9%) is also observed for Nunavut. In addition, in Nunavut, all data collected are usable which means that the final nonresponse is due only to the collection nonresponse rate. Nonresponse rates in Nunavut and Northwest Territories are smaller than 20% while rates over 30% are observed in Nova Scotia and Ontario. The higher final nonresponse rate in Nova Scotia is due in part to a higher rate of out-of-balance questionnaires (5.2%). Ontario has the highest nonresponse rate at 37.2%. The highest rates of no contact (9.0%) and refusal (25.0%) are also observed in Ontario.

The vacancy rates are shown in Table 2.1b, but it should be kept in mind that vacant dwellings do not contribute to the bias of the sample if they are correctly identified. By analysing vacancy rates, we can detect dwelling identification problems associated with the collection process. The national vacancy rate for the 2003 SHS is 11.0%.

2.2 Nonresponse according to urbanization level

Nonresponse varies according to urbanization level. The various rates at the national level are shown by urbanization level in Table 2.2.[4]

Table 2.2
Nonresponse and vacancy rates (%) by urbanization level

Urbanization category	Vacancy rate	Collection nonresponse rate			Unusable data rate			Total nonresponse rate(at estimation stage)
		Total	No contact	Refusal	Total	Incomplete	Out-of-balance	
Urban								
1,000,000 or more	4.8	31.8	9.4	22.4	2.0	1.5	0.5	33.8
500,000 to 999,999	5.7	25.3	6.3	19.0	1.6	0.8	0.7	26.9
250,000 to 499,999	5.4	30.1	8.2	21.9	6.2	1.2	5.0	36.3
100,000 to 249,999	7.6	24.0	6.5	17.5	4.5	1.3	3.2	28.5
30,000 to 99,999	6.7	26.4	7.1	19.4	3.4	1.7	1.7	29.8
Less than 30,000	10.6	20.0	5.8	14.2	2.7	1.2	1.5	22.7
Rural	23.1	18.9	5.4	13.5	3.4	1.3	2.0	22.3
Total	11.0	24.6	6.9	17.7	3.0	1.3	1.7	27.7

The final nonresponse rate generally increases with urbanization level. According to Table 2.2, the "500,000 to 999,999" and "100,000 to 249,999" groups and, to a lesser extent, the "1,000,000 or more" group, go against this rule. For the "500,000 to 999,999" group, this can be explained in part by the fact that this group has the lowest rate of unusable data (1.6%). For the "100,000 to 249,999" group, this is due to a lower refusal rate (17.5%) than those of urbanization regions of 30,000 inhabitants and more. The final nonresponse rate of 36.3% for the urbanization category "250,000 to 499,999" can be attributed to the collection nonresponse rate (30.1%), which itself is mostly due to the rate observed in Ontario (38.1%, data not shown), as well as the rate of unusable data (6.2%), which itself is mostly due to the rate observed in Nova Scotia (9.8%, data not shown).

The collection nonresponse rate also increases with urbanization level. There is a difference of nearly 12% between the urbanization categories "less than 30,000" and "1,000,000 or more". Refusals account for more than 60% of the

4. Tables on nonresponse rates by urbanization level and province are available on request from the Household Survey Methods Division.

total nonresponse at each level of urbanization. Although the urbanization category "500,000 to 999,999" has the lowest total nonresponse rate among urban regions of 30,000 inhabitants or more, this category has the highest proportion of nonresponse (70.6%) due to refusals. The urbanization category "1,000,000 or more" has the highest rates of no contact (9.4%) and refusal (22.4%).

From an examination of the vacancy rate by urbanization level, it appears that the vacancy rate at the rural level (23.1%) is twice that for low-population urban areas (10.6%). The latter also shows a rate that is higher than for the high-population urban areas. This phenomenon is also observed in the LFS and may be explained by a greater number of seasonal dwellings in rural areas. The same factor also explains the higher vacancy rates in the Atlantic provinces, as illustrated in Table 2.1b, and especially in Prince Edward Island, which has a high proportion of rural dwellings.

2.3 Nonresponse according to income strata

Since income information is not available for nonrespondents, it is not possible to compare nonresponse rates according to income. However, the LFS sample design, used for the SHS, was designed in such a way that in nine large cities there are strata consisting of geographic areas where the average household income exceeds $100,000, and in seven large cities there are strata consisting of apartments inhabited by households with an average income of less than $20,000. Even though the number of such strata is small and accounts for only a small number of dwellings in the SHS sample (approximately 580 for high income and 160 for low income strata, or less than 3% of the sample), the comparison of nonresponse rates for these two groups in relation to the other strata is revealing. Table 2.3 shows these results. Note that results from this table exclude the supplementary sample in Quebec. Since the supplementary sample was not selected from the LFS sampling frame, such strata classification (high-income, regular, low-income) is not available for that particular sample.

Table 2.3
Comparison of nonresponse and vacancy rates (%) in high-income and low-income strata in relation to other strata

Stratum type based on income[1]	Vacancy rate	Collection nonresponse rate			Unusable data rate			Final nonresponse rate (at estimation stage)
		Total	No contact	Refusal	Total	Incomplete	Out-of-balance	
High-income	4.1	39.8	9.4	30.5	2.4	1.5	0.9	42.2
Regular	11.7	24.1	6.6	17.4	3.2	1.3	1.9	27.3
Low-income	3.7	25.2	11.9	13.3	2.1	1.4	0.7	27.3
Total	11.4	24.5	6.7	17.7	3.2	1.3	1.9	27.6

1. Excluding the supplementary sample in Quebec.

The final nonresponse rate (42.2%) in high-income strata is much higher than in regular or low-income strata. The refusal rate for high-income strata is over 30%, which is about twice the rate of other types of strata.

Households in low-income strata have the same final nonresponse rate and a collection nonresponse rate similar to those of the regular strata. However, the causes of the nonresponse are different for the two types of strata. For the regular strata, collection nonresponse rate is mainly due to refusals, while for the low-income strata it is approximately equally attributable to refusals and no-contact.

As for the 1997 to 2002 SHS, the vacancy rate is higher for regular strata than for each of the other two strata. In high-income and low-income strata, the vacancy rates are similar. The vacancy rate in low-income strata is at 3.7%, up from a rate of 1.8% in 2002.

2.4 Adjustment for nonresponse

To compensate for nonresponse, the weights in the SHS are inflated by the inverse of the weighted response rate within certain groups defined on the basis of the different urbanization levels in each province. The weighted rates differ from the rates presented in this section since the former takes into account the sampling weight of each household. An algebraic description of the nonresponse adjustment is provided in Appendix A.

The weights adjustment for nonresponse takes into account the differences in nonresponse by urbanization level as described in Section 2.2. It will reduce the bias to the extent that the characteristics of respondents and nonrespondents are similar for a given urbanization level.

3. Coverage errors

In the design of the survey, the target population was defined. It is useful to go over this definition, since a good understanding of the target population is necessary in order to properly interpret the survey data. One should note that SHS, with the exception of Quebec's supplementary sample this year, uses the LFS sampling frame.

Target population

> The target population consists of individuals living in private households. It therefore excludes residents of institutions such as prisons, chronic care hospitals or senior citizens' homes, as well as members of religious orders and other groups living communally, members of the Armed Forces living in military compounds, and individuals residing permanently in hotels or rooming houses. Also excluded are foreign countries' official representatives residing in Canada and their families as well as individuals residing on Indian reserves or public lands (with

exception for the Territories). With these exclusions, the survey covers nearly 98% of the population in the 10 provinces. In the Yukon, the coverage of the population is 88 %. The coverage of the Northwest Territories represents 92 % of the population and the coverage of Nunavut represents 89 % of the population.[5]

We did not collect data from persons temporarily living away from their families (for example, students at university) because the data would be gathered from their families if selected in the sample.

Coverage errors result from inadequate representation of the target population based on the units of the sampling frame. Some units of the target population may be omitted from the sampling frame, in which case there is undercoverage. Other units that are not in the target population may be included by error, or some units may be included more than once. These units are responsible for overcoverage.

3.1 Undercoverage and overcoverage: slippage rates

In the SHS, the sample is selected using a list of dwellings in each selected cluster. Factors contributing to undercoverage are: the omission of dwellings in the creation of the list, new dwellings that are added between the creation of the list and the interviewer's visit (mainly in developing areas), and the erroneous classification of vacant dwellings. The inclusion of dwellings that are not within the boundaries of the cluster is a source of overcoverage. Similarly, errors can take place during data collection, due to improper identification of persons as members of the selected household. These errors also contribute to undercoverage or overcoverage.

A good representation of the target population is essential to the production of realistic expenditure estimates. The number of people per household is also an important characteristic in the estimation of average household expenditures. Therefore, it is necessary that the sample not only adequately represent the individuals in the target population, but also the distribution of households according to their size.

In 1999, a weighting strategy that uses new controls was introduced. This method results in a better correction of the representation of the target population by using a more detailed age-sex grouping than was used previously and for which the coverage varies from one group to the other.

There is generally a net undercoverage of the number of persons in the SHS. This undercoverage is corrected by an adjustment of weights using auxiliary data based on post-censal demographic estimates. The slippage rate (see Appendix A) is a measure of the percentage of difference between the auxiliary data and the survey estimates calculated using weights not adjusted with these data.[6] Tables 3.1 and 3.2 show slippage rates by age-sex group at the national level

5. In terms of households, the coverage of the Yukon, the Northwest Territories and Nunavut represents 88%, 93% and 90% respectively of households.
6. The subweight which is the survey weight adjusted for nonresponse is used (see Appendix A).

and at the provincial and territorial level respectively, while Table 3.3 presents these rates for the household size categories used for the weight adjustment. A positive rate indicates overcoverage of the number of persons or households in the survey.

Table 3.1
National slippage rates by age-sex group

National slippage rates by age-sex group				
	Age	Sex		Total
		Male	Female	
Canada[1]	0-6 years	-1.0	-6.5	-3.7
	7-17 years	-6.0	-6.8	-6.4
	18-24 years	-16.9	-14.7	-15.8
	25-34 years	-24.2	-15.7	-20.0
	35-54 years	-15.0	-10.1	-12.5
	55-59 years	-12.2	-8.0	-10.1
	60-64 years	-10.1	-6.8	-8.4
	65-69 years	-4.5	-5.2	-4.9
	+	-8.9	-7.5	-8.1
	Total	-12.8	-9.8	-11.3

1. Excluding the territories.

For the 2003 SHS, the national undercoverage rate was 11.3%. If we analyze Table 3.1, we can see that at the national level, there is always a net undercoverage for each age group. Except for the category 65 to 69 years old, the undercoverage rates for children (0 to 6 and 7 to 17) are smaller than those of the adults. The undercoverage rate for all children combined is 5.5%, while it is 13.0% for adults (data not shown). The slight undercoverage for the 0 to 6 year-old males is mostly due to the overcoverage in Quebec (1.7%) and Ontario (3.6%) for that age-sex group (see Table 3.2). Similarly, the lower undercoverage rate for the category 65 to 69 years is due to the overcoverage in Quebec (11.9%) among women of that age group, as well as the overcoverage in Ontario (11.2%) among men of that age group (see Table 3.2).

The highest national rates occurred among 25 to 34 year-old men, 18 to 24 year-old men and 25 to 34 year-old women. Except for the category 65 to 69 years, the undercoverage rate for women is always smaller than the undercoverage rate for men.

As mentioned previously, the SHS uses the LFS sampling frame. Over the same period, the national LFS undercoverage rate was 10.7% (reference [5]). This is slightly lower than the 12.6% SHS rate for those 15 years or older (data not shown).

Table 3.2
Slippage rates for the provinces and territories by age-sex group

Slippage rates by age-sex group														
Sex	Age	Newfoundland and Labrador	Prince Edward Island	Nova Scotia	New Brunswick	Quebec	Ontario	Manitoba	Saskatchewan	Alberta	British Columbia	Yukon	Northwest Territories	Nunavut
Male	0-6	-10.7	9.9	-4.5	2.5	1.7	3.6	-3.5	-17.3	-2.2	-14.3	-0.9	-11.4	-12.7
	7-17	-6.0	-4.6	-6.5	-7.2	4.0	-10.7	-0.9	-12.3	-4.2	-9.6			
	18-24	-35.5	-21.0	-27.4	-21.5	-2.9	-21.2	-30.4	-33.3	-11.5	-20.4	-28.2	-22.0	-16.0
	25-34	-29.6	-18.7	-27.2	-18.6	-18.1	-30.0	-20.2	-19.0	-16.4	-26.5			
	35-54	-11.4	-12.5	-3.6	-15.7	-9.5	-16.3	-14.6	-22.5	-23.2	-16.4			
	55-59	-20.2	-24.6	-29.4	-11.1	-13.2	-3.9	-26.1	-14.9	-20.0	-18.4			
	60-64	-20.7	-9.4	-9.2	-12.9	-22.0	2.0	-30.6	-5.9	-11.6	-14.2			
	65-69	-0.3	-3.6	-3.8	1.9	-16.3	11.2	-32.5	-0.2	-11.5	-19.6			
	70 +	-2.7	3.8	-19.5	-10.6	-2.4	-13.6	7.8	5.9	-10.1	-12.8			
	Total	**-15.5**	**-10.2**	**-12.7**	**-12.6**	**-7.9**	**-13.6**	**-14.0**	**-16.6**	**-14.4**	**-16.9**	**-21.7**	**-18.8**	**-14.6**
Female	0-6	-10.3	14.3	0.5	9.9	6.3	-13.3	-7.7	-5.6	-10.6	-8.6	-20.4	-25.3	-16.8
	7-17	-9.8	-3.4	-4.0	-10.7	-5.4	-6.0	7.4	-19.8	-3.5	-15.1			
	18-24	-17.1	-20.5	-10.9	-11.5	-6.8	-17.6	-9.4	-19.3	-8.0	-26.6	-24.6	-15.4	-8.6
	25-34	-18.3	-12.5	-16.3	-17.9	-7.2	-16.9	-22.1	-24.2	-9.7	-27.0			
	35-54	-8.5	-5.0	-0.3	-6.6	-3.9	-12.0	-3.0	-15.4	-17.1	-14.4			
	55-59	-6.9	-12.4	-22.0	-10.3	-17.4	6.5	-22.0	-3.4	-17.9	-18.2			
	60-64	-8.1	0.7	-12.1	-5.4	-14.2	-1.0	-2.3	-1.7	-5.1	-10.6			
	65-69	-5.4	-21.1	-1.5	-8.7	11.9	-11.2	-18.8	-3.9	-25.5	-3.8			
	70 +	-13.0	-7.1	-1.0	-0.5	-8.3	-9.0	12.0	9.1	-11.4	-11.9			
	Total	**-11.1**	**-7.0**	**-6.0**	**-7.6**	**-5.3**	**-10.5**	**-4.9**	**-12.2**	**-11.9**	**-16.4**	**-23.7**	**-18.6**	**-12.1**
Total		**-13.3**	**-8.6**	**-9.3**	**-10.1**	**-6.6**	**-12.1**	**-9.4**	**-14.4**	**-13.1**	**-16.6**	**-22.7**	**-18.7**	**-13.4**

We observe a net undercoverage for all provinces and territories, with the rates varying from 6.6% to 22.7%. The magnitude of the undercoverage is greater for the Northwest Territories and Nunavut. Quebec has the lowest undercoverage rate at 6.6%. Nevertheless, this lower rate observed in Quebec is to some extent attributed to the supplementary sample selected in that province in 2003. When excluding Quebec's supplementary sample, the net undercoverage for that province went from 6.6% to 8.8 % (data not shown). However, a low overall rate of undercoverage is not a guarantee of a better coverage. For example, Prince Edward Island's overall slippage rate (-8.6%) concealed the worst case of overcoverage for a provincial age-sex group (14.3% among 0 to 6 year-old females). On the other hand, despite an overall slippage rate of -16.6%, British

Columbia has only the twelfth worst case of undercoverage (27.0% among 25 to 34 year-old women).

Among the provinces, the highest undercoverage rate occurred among 18 to 24 year-old men in Newfoundland and Labrador (35.5%). The magnitude of the undercoverage is higher among 25 to 34 year-old men. Indeed, for all provinces we observe an undercoverage rate greater than 16.0%, which explains the overall undercoverage rate of 24.2% at the national level (see Table 3.1). We can also see that the pattern of slippage rates differs substantially for age-sex groups from one province to the next.

Table 3.3
Slippage rates for the provinces and the Yukon[7] by household size

Province or territory	Slippage rate			
	Households	One-person households	Two-person households	Three-person and more households
Canada[1]	-8.5	-2.2	-7.5	-13.2
Newfoundland and Labrador	-8.1	11.0	-5.1	-17.2
Prince Edward Island	-8.3	-9.8	-3.3	-11.3
Nova Scotia	-6.7	0.6	-8.2	-9.8
New Brunswick	-4.9	6.2	3.1	-17.6
Quebec	-5.0	-3.8	-3.0	-8.0
Ontario	-9.6	-2.9	-8.6	-13.9
Manitoba	-5.7	5.5	-9.5	-10.5
Saskatchewan	-9.4	2.8	-8.0	-19.4
Alberta	-10.6	-5.7	-14.2	-10.5
British Columbia	-11.8	-0.3	-9.6	-21.5
Yukon	-14.9	-2.0	-12.7	-26.7

1. Excluding the Northwest Territories and Nunavut.

Nationally, the number of households was underestimated by 8.5%. This slippage rate is slightly lower than the -11.3% slippage rate for individuals.

Among the provinces and the Yukon, there is a substantial variation in the slippage rate for one-person households. This rate ranges from -9.8% for Prince Edward Island to 11.0% for Newfoundland and Labrador. The same phenomenon occurs with respect to two-person households but with less variation. For two-person households, the slippage rate ranges from -14.2% in Alberta to 3.1% in New Brunswick. The slippage rate for households of three or more persons ranges from -26.7% for the Yukon to -8.0% in Quebec.

Except for New Brunswick, there is always undercoverage for two-person households and households of three or more persons. Note that for households

7. For 2003 reference year, the sampling weights were not adjusted to reflect post-censal estimates of the number of households in the Northwest Territories and in Nunavut (see Section 3.2).

of three or more persons, the undercoverage is generally greater than 10%. Again here, the lower rate in Quebec (8.0%) for that latter category is to some extent attributed to the supplementary sample selected in that province in 2003. When excluding Quebec's supplementary sample, the net undercoverage for that province went from 8.0% to 10.3 % (data not shown). Except for Alberta, the greatest undercoverage is observed for households of three or more persons.

3.2 Adjustment at the population and household levels

To correct the problem of the sample's representativeness shown in Tables 3.1 and 3.2 and to reduce the resulting bias, the survey data are adjusted during weighting using demographic estimates for the age groups defined in these tables, for each province and territory. For more information on the adjustment's methodology, see reference [1]. This adjustment reduces the bias but does not completely eliminate it entirely if the characteristics of the individuals omitted from the survey differ from those of individuals included for a given age group in a province.

It should also be noted that the effectiveness of the adjustment based on demographic estimates depends largely on the quality of those estimates and their accuracy in representing the target population of the survey. The demographic estimates are not error-free. They are post-censal estimates based on the population counts from the 1996 Census adjusted for net undercoverage, and they take into account recent statistics on migration, births, deaths, etc. These demographic estimates are adjusted to account for certain exclusions specific to household surveys, such as persons living in institutions. Conceptually, they differ slightly from the SHS target population in that they include persons living in non-institutional collective dwellings, such as members of groups living communally and individuals permanently residing in hotels or rooming houses. However, this difference is considered negligible, since such individuals represent less than 0.4% of the Canadian population.

To remedy the issue of the representativeness of the sample in terms of the number of households by size as illustrated in Table 3.3, the survey data are adjusted using supplementary data. By adjusting the SHS weights to reflect post-censal estimates of the number of households by size, the goal is to compensate for the bias resulting from inadequate representation of households. However, the bias will not necessarily be eliminated if characteristics of households not interviewed (i.e., omitted or non-respondent households) differ from those of responding households for a given household size. As in the case of demographic estimates of population, the effectiveness of the adjustment will depend on the quality of the supplemental data on the number of households. As such, controls on the number of households computed for SHS showed a break in the series of controls that have been produced up till now for Northwest Territories and Nunavut. While controls up to January 2001 were similar to those of the Census data, a gap was observed from those of January 2002. In an effort to reduce the impact of such a gap on the series of estimates from SHS, some changes were made to the methodology used in the production of the supplemental data on the number of households for those two territories for the 2001 SHS weighting. On the other hand, for all provinces and in the Yukon, no such problem is observed for the controls based on the 1996 Census. For the

2003 SHS, the gap in the series of controls on the number of households was still present for those two territories. Note that the new series of controls on the number of households based on the 2001 Census is available and this last series does not reveal any problems for those two territories. Before introducing the new series based on the 2001 Census, some evaluations must be done in order to measure the impact of the new controls on the survey estimates. For the above mentioned reasons and since the changes made for the 2001 SHS were meant to be temporary in nature, it has been decided to not use the controls on the number of households for the Northwest Territories and Nunavut for the 2003 SHS weighting. Although the sampling weights were not adjusted to reflect post-censal estimates of the number of households (based on 1996 Census) in the Northwest Territories and in Nunavut, the estimates of the total number of households obtained from the final weights are similar to the controls on the number of households based on the 2001 Census for those two territories. That is, we obtain a net overcoverage of 1.3 % for the Northwest Territories and a net undercoverage of 4.0 % for Nunavut.

In addition to demographic estimates of age-sex groups by province, three other groups of supplementary data are used during weighting to adjust survey data and thereby improve their representativity. The first set of data is used to control for the number of children and adults in certain major cities. The second is designed to control for the number of lone-parent households and couples with children by province. Finally, counts for major categories of income from wages and salaries are used when adjusting weights to ensure a certain degree of consistency between the income distributions from the SHS and from outside sources.

4. Response errors

Response errors represent a lack of accuracy in responses to questions. They can be attributed to different factors, including a questionnaire that requires improvements, misinterpretation of questions by interviewers or respondents, and errors in respondents' statements.

In the SHS, there can be various reasons for errors in respondents' statements. First, there are recall errors that occur when a respondent forgets expenditures made during the period covered by the survey (which corresponds to the calendar year), or when a respondent provides an erroneous value because of the time interval that has elapsed between the time of purchase and the date of the interview. Recall errors are probably the survey's largest source of response error, since the reference period is long (12 months) and a great variety of information is requested.

One of the main measures taken to minimize recall error in the SHS is to calculate the difference between receipts (income and other amounts received by the household) and disbursements (expenditures plus net change in assets and liabilities) for each household. When the difference exceeds 10% of receipts or disbursements, with the higher amount being retained, respondents are contacted again in order to obtain additional information and to try to identify

errors or omissions. The respondent is also encouraged to consult various documents (invoices, bank statements, etc.) in order to provide more accurate data. To determine expenditures for small items purchased at regular intervals, interviewers generally suggest that respondents estimate the frequency of the purchases and the price generally paid in order to derive expenditures for a 12-month period.

A second source of error in respondents' reporting is telescopic error, which consists of including in the reference period events that occurred before or after it. In the SHS, the use of the calendar year is considered to provide a good marker for the start of the reference period. Furthermore, since the reference period is a long one, telescopic error has less impact.

Responses by proxy can also contribute to response error. The household member who made an expenditure is generally best able to report it accurately. This is definitely the case with, say, personal purchases. Expenditures reported by an intermediary are more likely to be tainted by response error, and this type of error tends to have a greater effect on certain types of expenditures.

Among other sources of response error, the extent of the respondent's co-operation should not be overlooked. For personal reasons, the respondent may decide not to mention particular expenditures or decide to twist the facts.

In the SHS, another factor is the response burden, owing to the length of the interview and the great variety of items to be reported, as well as the pace of the interview. This can lead to respondent fatigue and affect the quality of the responses obtained. The interview time varies greatly from one household to another, depending on household size, income and various other characteristics. For some households, the interview can take more than five hours.

It should be stressed that questions were added to the 2001 SHS. Among other things, for 2001 only, extra questions were included in the survey so that data from the SHS could be used in the weighting of the Consumer Price Index. This change may affect historical comparisons for a few variables. For example, questions were added under "Personal care preparations" to collect specific information about hair care products, makeup, fragrances, deodorants and oral hygiene products. As a result of these extra questions, respondents may have given more precise information and the increase in the estimate for "Personal care preparations" may have been at least partly caused by an improvement in respondent recall. The effect of additional questions on estimates is difficult to quantify. However, in 2002 when the extra questions were removed, the estimate for personal care spending decreased again.

While response errors are a major source of error in a historical interview, they are the aspects of data quality that are the hardest to measure. Generally, it is necessary to conduct quite costly special studies in an attempt to measure them. Efforts are made to combat response errors by using survey techniques designed to reduce them.

5. Processing errors

Processing errors can arise in all types of data handling. The main stages of data processing are coding, data entry, editing, imputation of partial nonresponse and weighting. In the SHS different procedures are applied at each stage in order to minimize processing errors and the survey estimates are compared with other data sources prior to release. Errors related to the adjustments made at the weighting stage have been described in sections 2 and 3. The other types of processing errors are covered in this section.

Coding is necessary for only a few questions. This is done by the interviewer and subsequently verified by a senior interviewer. Before 2001, data entry was done with the help of an automated verification system that grouped the questionnaires into batches and chose some questionnaires from each batch to be entered a second time. Any errors found were to be corrected. If the number of errors in a batch was greater than a certain threshold, then the entire batch was submitted for re-entry. Due to the introduction of a new data capture system (BLAISE), there was no questionnaire batch verification procedure in 2003. However, some edits were implemented in the new data capture system to ensure consistency of data captured. The results of a preliminary data capture study seem to show that data capture error rates of the new system are similar to the ones of the old system.

The first stage of automated verification is done after each questionnaire has been verified manually by both the interviewer and the senior interviewer. It is ensured that the respondent's answers follow some essential consistency rules. Unusual situations that may justify corrections are also identified. This stage of verification is done in Statistics Canada's regional offices in case it is necessary to recontact respondents if some supplementary information is required to resolve inconsistencies in the answers provided. Specially-trained members of the verification teams solve any problems identified. Thereafter, other verification checks are done at head office and invalid responses are corrected.

The processing of SHS data also involves imputation for partial nonresponse. Partial nonresponse occurs when the respondent refuses to answer or does not know the answer to certain questions. The imputation approach differs depending on whether the data is categorical or continuous. Categorical data takes on only specific values (as in yes/no questions or type of dwelling questions), while continuous data can take any numerical value (as for income and expenditure data).

Income and expenditure data are imputed using the nearest neighbour technique. The imputation is done on one group of variables at a time, with the groups chosen by taking the relationships among the variables into account. A group generally corresponds to a section of the questionnaire. For every group, the missing values of a recipient (a household that has some missing data for at least one of these variables) are imputed from data of the most similar record among all donors (households that have no missing values for these variables). For each recipient the closest donor is chosen as the one that minimizes a particular distance function. This function is based on matching variables that

are chosen because they are correlated with the variables to be imputed. For example, the total income of a household is chosen as a matching variable for all sections pertaining to expenditures. It must also be ensured that, after receiving the donor values, the recipient household satisfies some consistency rules. In general, the imputation is done at the household level, but in some groups (e.g., income and clothing expenditures), the imputation is done at the person level since the original data is collected at that level.

Note that since 2001, the imputation of all expenditure and income data is done using the Canadian Census Edit and Imputation System (CANCEIS) of Statistics Canada. This new system is based on slightly different methodology from the one used by the previous system. The new system allows a better use of categorical variables as matching fields when selecting a donor. The new system was tested prior to its implementation and the results it gave were similar to those with the old system. Moreover, this system allows for the imputation of both continuous and categorical data. Starting with 2003, categorical data, which are obtained mainly in the facilities and equipment section of the questionnaire, are imputed with the CANCEIS system. The categorical data were previously imputed with the help of a "hot deck" imputation technique that randomly chooses a donor from a group of answering households with similar characteristics.

The bias caused by imputation of partial nonresponse is difficult to evaluate. It depends on the differences between respondents and nonrespondents as well as the ability of the imputation method to produce unbiased estimates. However, the imputation rates indicate the importance of partial nonresponse. They are presented in the following section.

5.1 Proportion of households or persons requiring imputation at national, provincial and territorial levels

A preliminary indication of the magnitude of partial nonresponse is the proportion of households requiring imputation and the number of variables imputed by household. The questionnaire can be divided into two major groups of variables: those collected at the household level and those collected at the individual level (such as income and clothing expenditure). For the latter, the respondent may provide only the total income or total clothing expenditures if he/she is unable to provide the breakdowns by source of income or type of expenditure. The level of imputation for the components of income and clothing expenditure is then larger, but this does not affect the total income, total clothing expenditure or total expenditure.

The percentage of households requiring imputation for household expenditure (excluding clothing expenditures and expenditures in the section on Personal Taxes, Security and Money Gifts) is presented in the next sub-section. The subsequent sub-section presents the percentage of persons requiring imputation for a clothing expenditure variable, the percentage of persons requiring imputation for an income variable and the percentage of persons requiring imputation for a variable in the section on Personal Taxes, Security and Money Gifts. Finally, the last sub-section presents the percentage of households requiring imputation for at least one of the categorical variables. After data imputation by the system, some corrections might have been needed on both

imputed and non-imputed variables aiming to ensure data consistency. The actual percentage of records requiring this kind of modification is about 1% at the household level. The results are provided at the national, provincial and territorial levels. This gives an indication of which provinces are more affected by imputation.

5.1.1 Household expenditure imputation by province and territory

The percentage of usable households that required imputation for an expenditure variable (excluding clothing expenditures and expenditures in the section on Personal Taxes, Security and Money Gifts) is presented in Table 5.1. Usable households correspond to all households living in eligible dwellings, excluding households who could not be contacted, who refused to participate in the survey, or who provided unusable data (see Section 2.1). The table is broken down by the number of imputed variables (out of 229) for a household.

Note that regular mortgage payments and mortgage insurance premiums are included under the shelter costs and thus under the total expenditure. Starting with 2002, these two variables were added in the calculation of imputation rates shown in Table 5.1. The impact of this modification is a higher overall imputation rate.

Table 5.1
Households requiring expenditure imputation by province and territory

Province or territory	Households (%) requiring imputation for **expenditure variables**[1] (excluding clothing expenditures and expenditures in the section on Personal Taxes, Security and Money Gifts)			
	Number of variables imputed (out of 229)			
	1	2	3 or more	Total
Canada	**9.9**	**1.8**	**1.1**	**12.8**
Newfoundland and Labrador	15.5	2.0	0.7	18.2
Prince Edward Island	16.0	1.5	0.0	17.6
Nova Scotia	13.2	2.5	1.8	17.5
New Brunswick	8.4	1.2	0.7	10.3
Quebec	5.8	0.5	0.2	6.6
Ontario	11.3	3.2	3.0	17.5
Manitoba	8.9	1.6	0.4	10.9
Saskatchewan	8.7	1.5	0.7	10.9
Alberta	9.3	1.3	0.7	11.3
British Columbia	9.9	3.2	2.5	15.7
Yukon	13.0	1.3	0.7	15.0
Northwest Territories	12.1	3.2	0.3	15.6
Nunavut	7.3	1.4	0.5	9.2

1. Includes regular mortgage payments and mortgage insurance premiums

Table 5.1 indicates that 12.8% of households required some expenditure imputation (excluding the Clothing section and the Personal Taxes, Security and Money Gifts section) at the national level, but nearly 77% of them had only one variable imputed. The overall imputation rate is 8.3% (data not shown) when excluding regular mortgage payments and mortgage insurance premiums, which is similar to rates obtained in previous years. There are 5.3% of households (or 15.6% of households when selecting only households that reported mortgages on dwellings that they owned and occupied) that need an imputation for the mortgage insurance premiums.

There are very few households that had more than one variable imputed (2.9%). At the provincial or territorial level, Quebec (6.6%) and Nunavut (9.2%) have the lowest imputation rates. In fact, this province and that territory are the only ones with an imputation rate smaller than 10%. The highest rates are observed in Newfoundland and Labrador (18.2%), Prince Edward Island (17.6%), Nova Scotia (17.5%) and Ontario (17.5%). Ontario and British Columbia have the highest rates among households that required imputation for more than one variable. In those two provinces, about one-third of the households that required imputation had two or more variables imputed. The low percentage of households (particularly when excluding regular mortgage payments and mortgage insurance premiums) for which some variables had to be imputed, combined with the low number of variables that had to be imputed when imputation was necessary, suggests that the imputed values should not have a strong impact on the estimates.

5.1.2 Person expenditure and income imputation by province and territory

Since some respondents provide only totals for clothing expenditure and income variables, a two-step procedure is used to impute these variables (at the individual level). Individuals who require imputation of only certain components are imputed first. Then, they are followed by those for which totals are available but imputation on all components is required (see reference [1] for a more detailed description of this process).

The percentage of usable individuals (persons who are members of usable households) requiring imputation for an income variable are presented by province and territory in Table 5.2. The percentage of persons who had exactly one variable imputed, those who had two or more variables (but not all) imputed and the percentage of persons for which only total income was available (and hence required having all their components imputed) are shown. The total percentage of persons requiring some form of income imputation is also provided. The second to last column of Table 5.2 indicates the total percentage of persons requiring some form of imputation, except for clothing expenditure variables. The last column of Table 5.2 indicates the total percentage of persons requiring some form of imputation for the Personal Taxes, Security and Money Gifts section of the questionnaire.

Note that questions related to personal income, personal taxes, security and money gifts are asked to each household member aged 15 years old or over on December 31 of the reference year. Thus, this year, the percentage of persons requiring some form of imputation for income variables as well

as for the Personal Taxes, Security and Money Gifts section was calculated using only the persons aged 15 years old or over and was not based on all persons as done in previous years. The impact of this modification resulted in an imputation rate slightly higher for those variables. As done in previous years, the percentage of persons requiring imputation for clothing expenditure variables is based on all persons since those expenditure questions are asked for each household member.

Table 5.2
Persons requiring income imputation, persons requiring clothing expenditure imputation and persons requiring imputation for variables in personal taxes, security and money gifts section by province and territory

Province or territory	Percentage of persons requiring imputation for **income variables**				Percentage of persons requiring imputation for at least one of the 11 clothing expenditure variables	Percentage of persons requiring imputation for at least one of the 15 variables in the section on personal taxes, security and money gifts
	1 income variable imputed	2 or more income variables imputed (not all)	All income variables imputed (total income known)	**Total** (any form of income imputation)		
Canada	**1.0**	**0.3**	**3.3**	**4.7**	**18.6**	**3.2**
Newfoundland and Labrador	0.5	0.1	2.9	3.7	7.4	1.9
Prince Edward Island	0.1	0.2	8.1	8.6	12.5	1.0
Nova Scotia	0.6	0.1	3.9	4.7	15.2	5.1
New Brunswick	0.5	0.2	6.3	7.1	14.8	2.4
Quebec	0.6	0.1	1.9	2.6	19.9	1.2
Ontario	2.3	0.7	3.2	6.2	16.3	6.8
Manitoba	1.6	0.4	2.1	4.2	19.1	2.4
Saskatchewan	0.4	0.6	3.0	4.2	24.5	3.0
Alberta	0.3	0.3	3.1	3.8	20.9	2.3
British Columbia	2.4	0.4	4.1	7.0	20.0	5.6
Yukon	0.5	0.4	4.4	5.3	40.9	4.2
Northwest Territories	0.7	0.0	1.3	2.0	34.1	1.3
Nunavut	0.0	0.0	0.8	0.8	26.3	0.8

These results show that nearly 5% of persons from usable households had some imputation performed on at least one income variable. For 70% of them, the respondent gave the total income but all their components had to be imputed. For many of the remaining persons requiring imputation, only one component of

income (one variable) had to be imputed. Note that this year, the imputation rates for income variables are based on persons aged 15 years old and over. The overall imputation rate is 3.8% (data not shown) when computed over all persons, which is comparable to the 4.1% rate obtained in 2002. Provincially, the percentages of persons requiring some imputation on at least one income variable range from a low of 0.8% for Nunavut to a high of 8.6% for Prince Edward Island. The highest imputation rates are observed in Prince Edward Island (8.6%), New Brunswick (7.1%), British Columbia (7.0%) and Ontario (6.2%). In Prince Edward Island and New Brunswick, almost all income imputation is attributed to cases where totals are available but imputation on all components is required. Conversely, in Ontario and British Columbia, the income imputation is mainly attributable to cases where only one component had to be imputed and cases where totals are available but imputation on all components is required.

From the second to last column of the table, it can be seen that about 19% of persons required imputation for at least one of the clothing expenditure variables. The rates at the provincial and territorial levels range from 7.4% for Newfoundland and Labrador to 40.9% in the Yukon. Almost all these people provided their total expenditure on clothing but required imputation of the components. Newfoundland and Labrador is the only province with imputation rate smaller than 10%. The imputation rates are lower in the Atlantic provinces and conversely, higher in the Territories. The higher level of imputation required on clothing expenditure components implies that the estimates for these components could be greatly affected by imputation, while the effect on the estimates for total clothing expenditures will be negligible.

From the last column of the table, results show that about 3% of persons had some imputation performed on at least one variable in the Personal Taxes, Security and Money Gifts section. Note that this year, the imputation rate is based on persons aged 15 years old and over. The overall imputation rate is 2.6% (data not shown) when computed over all persons, a rate identical to the one obtained in 2002. Provincially, these percentages are also low, ranging from a low of 1.2% for Prince Edward Island to a high of 6.8% for Ontario. The provinces of Nova Scotia, Ontario and British Columbia have an imputation rate greater than 5%. In those three provinces, the higher imputation rate is due to the variable corresponding to the income tax paid on the 2003 income that required in proportion more imputation than for other provinces or territories.

5.1.3 Imputation of categorical variables by province and territory

The percentage of usable households that required imputation for at least one of the categorical variables is presented in Table 5.3. The table is broken down by the number of imputed variables (out of 56) for a household. Categorical variables that required imputation can be found in the following sections of the questionnaire: Dwelling Characteristics (with the exception of the dwelling type variable); Facilities Associated with the Dwelling; Tenure (with the exception for variables related to a tenure change during the reference year); Tobacco and Miscellaneous for variables pertaining to purchases through direct sales (yes/no questions). Note that other categorical variables from the questionnaire, such as the household composition variables or questionnaire skips, are edited and

validated by subject matter personnel from the Income Statistics Division. Therefore, those latter variables are not imputed using the nearest neighbour technique.

Table 5.3
Households requiring imputation of categorical variables by province or territory

Province or territory	Households (%) requiring imputation of **categorical variables**			
	Number of variables imputed (out of 56)			
	1	**2**	**3 or more**	**Total**
Canada	**4.7**	**0.6**	**1.2**	**6.4**
Newfoundland and Labrador	3.1	0.1	0.9	4.2
Prince Edward Island	2.1	0.3	0.3	2.8
Nova Scotia	3.0	0.2	0.7	3.9
New Brunswick	2.5	0.2	0.8	3.5
Quebec	3.5	0.5	0.6	4.6
Ontario	6.5	1.0	2.4	9.9
Manitoba	4.7	0.6	1.5	6.8
Saskatchewan	7.5	1.3	1.9	10.7
Alberta	5.8	0.2	1.0	7.0
British Columbia	6.7	1.0	2.1	9.8
Yukon	6.2	0.3	1.6	8.1
Northwest Territories	3.5	0.3	0.3	4.1
Nunavut	2.8	0.9	0.5	4.1

Table 5.3 indicates that 6.4% of households required some categorical imputation for dwelling characteristics, facilities associated with the dwelling, tenure and purchases through direct sales at the national level, but nearly 75% of them had only one variable imputed. At the provincial or territorial level, Prince Edward Island (2.8%), New Brunswick (3.5%) and Nova Scotia (3.9%) have the lowest imputation rates of categorical variables. The highest rates are observed in Saskatchewan (10.7%), British Columbia (9.9%) and in Ontario (9.8%).

References

[1] Tremblay, J. and Arsenault, S. 2001. *Methodology of the Survey of Household Spending.* Catalogue no. 62F0026MIE2001003. Ottawa. Household Survey Methods Division, Statistics Canada.

[2] Rao, J.N.K., Wu, C.F.J., Yue, K. 1992. Some recent work on resampling methods for complex surveys. *Survey Methodology* (Statistics Canada. Catalogue no. 12-001); 18(2):209-217.

[3] Statistics Canada, Income Statistics Division. 2003. *User Guide—Survey of Household Spending.* Catalogue no. 62F0026MIE2004003. Ottawa.

[4] Statistics Canada, Income Statistics Division. 2003. *Spending Patterns in Canada.* Catalogue no. 62-202. Ottawa.

[5] Statistics Canada, Household Survey Methods Division. 2003. *Labour Force Survey, Operations Report.* Survey 200312. Ottawa.

[6] Lapierre, B., Nadeau, C., Tremblay, J. et Gaudet, J. 2004. Improving the quality of estimates for a low-income population: use of a dual frame in the Survey of Household Spending, Proceedings of Statistics Canada Symposium 2004 (to appear).

Appendix A

Algebraic notation

1. Nonresponse adjustment

The subweight (i.e. the design weight adjusted for nonresponse) for a household k, denoted as w_k^{NR}, is

$$w_k^{NR} = \pi_k^{-1} * \frac{1}{rate_g} \qquad with \qquad rate_g = \frac{\sum_{k \in s_{g,r}} \pi_k^{-1}}{\sum_{k \in s_{g,r}} \pi_k^{-1} + \sum_{k \in s_{g,nr}} \pi_k^{-1}}$$

where

$s_{g,r}$ is the set of respondents in nonresponse group g,

$s_{g,nr}$ is the set of nonrespondents (refusals, no contacts, unusable data) in nonresponse group g, and

π_k^{-1} is the design weight assigned to household k.

2. Calculation of the slippage rate

The slippage rate for a control group c, denoted as $rate_c$, is

$$rate_c = 100 * \frac{\left(\sum_{k \in s_{c,r}} w_k^{NR} \right) - t_c}{t_c}$$

where

$s_{c,r}$ is the set of respondents in control group c,

w_k^{NR} is the subweight of household k, and

t_c is the total of the auxiliary data for the control group c.

N° 62F0026MIF au catalogue — N° 006
ISSN : 1708-8887
ISBN : 0-662-70279-4

Document de recherche

Série de documents de recherche sur les dépenses des ménages

Enquête sur les dépenses des ménages de 2003 : Indicateurs de qualité des données

par Yi Li, Charles Mitchell, Sylvain Nadon et Paddison Wong

Division des méthodes d'enquêtes auprès des ménages
Immeuble R.H. Coats, Ottawa, K1A 0T6

Téléphone : 613 951-7355

Statistique Canada Statistics Canada

Canada

Comment obtenir d'autres renseignements

Toute demande de renseignements au sujet du présent produit ou au sujet de statistiques ou de services connexes doit être adressée à : Division de la statistique du revenu, Statistique Canada, Ottawa, Ontario, K1A 0T6 (613) 951-7355; (888) 297-7355 : revenu@statcan.ca).

Pour obtenir des renseignements sur l'ensemble des données de Statistique Canada qui sont disponibles, veuillez composer l'un des numéros sans frais suivants. Vous pouvez également communiquer avec nous par courriel ou visiter notre site Web.

Service national de renseignements	1 800 263-1136
Service national d'appareils de télécommunications pour les malentendants	1 800 363-7629
Renseignements concernant le Programme des services de dépôt	1 800 700-1033
Télécopieur pour le Programme des services de dépôt	1 800 889-9734
Renseignements par courriel	infostats@statcan.ca
Site Web	www.statcan.ca

Renseignements pour accéder au produit

Le produit nº 62F0026MIF au catalogue est disponible gratuitement. Pour obtenir un exemplaire, il suffit de visiter notre site Web à www.statcan.ca et de choisir la rubrique Nos produits et services.

Normes de service à la clientèle

Statistique Canada s'engage à fournir à ses clients des services rapides, fiables et courtois, et ce, dans la langue officielle de leur choix. À cet égard, notre organisme s'est doté de normes de service à la clientèle qui doivent être observées par les employés lorsqu'ils offrent des services à la clientèle. Pour obtenir une copie de ces normes de service, veuillez communiquer avec Statistique Canada au numéro sans frais 1 800 263-1136. Les normes de service sont aussi publiées dans le site www.statcan.ca sous À propos de Statistique Canada > Offrir des services aux Canadiens.

Statistique Canada
Division de la statistique du revenu

Série de documents de recherche sur les dépenses des ménages

Enquête sur les dépenses des ménages de 2003 : Indicateurs de qualité des données

Publication autorisée par le ministre responsable de Statistique Canada

© Ministre de l'Industrie, 2005

Tous droits réservés. Le contenu de la présente publication peut être reproduit, en tout ou en partie, et par quelque moyen que ce soit, sans autre permission de Statistique Canada sous réserve que la reproduction soit effectuée uniquement à des fins d'étude privée, de recherche, de critique, de compte rendu ou en vue d'en préparer un résumé destiné aux journaux, et/ou à des fins non commerciales. Statistique Canada doit être cité comme suit : Source (ou « Adapté de », s'il y a lieu) : Statistique Canada, nom du produit, numéro au catalogue, volume et numéro, période de référence et page(s). Autrement, il est interdit de reproduire quelque contenu de la présente publication, ou de l'emmagasiner dans un système de recouvrement, ou de le transmettre sous quelque forme et par quelque moyen que ce soit, reproduction électronique, mécanique, photographique, pour quelque fin que ce soit, sans l'autorisation écrite préalable des Services d'octroi de licences, Division du marketing, Statistique Canada, Ottawa, Ontario, Canada K1A 0T6.

Octobre 2005

N° 62F0026MIF2005006

ISSN : 1708-8887
ISBN : 0-662-70279-4

Périodicité : hors série

Ottawa

This publication is available in English upon request (Catalogue no. 62F0026MIE).

Note de reconnaissance

Le succès du système statistique du Canada repose sur un partenariat bien établi entre Statistique Canada et la population, les entreprises, les administrations canadiennes et les autres organismes. Sans cette collaboration et cette bonne volonté, il serait impossible de produire des statistiques précises et actuelles.

Ce document a été préparé par les membres de l'unité de l'Enquête sur les dépenses des ménages de la Division des méthodes d'enquêtes auprès des ménages (DMEM) :

Yi Li
Charles Mitchell
Sylvain Nadon
Paddison Wong

Les auteurs remercient l'équipe responsable de l'Enquête sur les dépenses des ménages de la Division de la statistique du revenu (DSR) pour leur collaboration dans la préparation de ce document.

Table des matières

Faits saillants **6**

Introduction **9**

1. Les erreurs d'échantillonnage **10**

1.1 Les mesures de l'erreur d'échantillonnage 10
1.2 Les coefficients de variation 11
1.3 Modèle pour dériver une approximation du CV 14
1.4 Suppression des données non fiables dans les tableaux d'estimations 15

2. La non-réponse **15**

2.1 Le taux de réponse, les taux de non-réponse et les taux de vacance 16
2.2 La non-réponse selon le niveau d'urbanisation 19
2.3 La non-réponse selon les strates de revenu 20
2.4 L'ajustement pour la non-réponse 21

3. Erreurs de couverture **22**

3.1 Le sous-dénombrement et le surdénombrement : les taux de glissement 22
3.2 L'ajustement au niveau de la population et des ménages 27

4. Les erreurs de réponse **28**

5. Les erreurs de traitement **30**

5.1 Proportion de ménages ou personnes nécessitant imputation, à l'échelle nationale, provinciale et territoriale 32

Références **38**

Annexe A Notation algébrique **39**

Faits saillants

Les erreurs d'échantillonnage

- Les coefficients de variation (CV) de l'estimation de la moyenne des dépenses totales par ménage varient entre 1,2 % et 2,3 % selon les provinces. Le CV à l'échelle nationale est de 0,7 %. Les CV sont plus élevés dans les territoires, soit 3,6 % au Yukon, 3,9 % dans les Territoires du Nord-Ouest et 5,9 % au Nunavut.

- Les coefficients de variation (CV) de l'estimation de la moyenne pour les différentes catégories de dépenses sommaires sont pour la plupart inférieurs ou égaux à 1,7 % à l'échelle nationale, et généralement inférieurs à 5,0 % à l'échelle provinciale. Les résultats pour les différentes catégories de caractéristiques des logements et l'équipement ménager sont similaires. La taille de l'échantillon étant moindre dans les territoires, les CV ont tendance à être plus élevés que ceux des provinces.

La non-réponse

- Le taux de réponse final est de 72,3 %. Les taux de réponse provinciaux et territoriaux s'échelonnent de 62,8 % en Ontario à 91,6 % au Nunavut.

- Le taux de non-réponse est de 27,7 %. La non-réponse est due aux refus (17,7 %), aux ménages qu'on n'a pas réussi à contacter (6,9 %) et aux ménages dont les données ont été considérées inutilisables (3,0 %).

- Le taux de non-réponse final a tendance à croître avec le niveau d'urbanisation. On observe un taux de non-réponse de 22,3 % en milieu rural, et un taux de 33,8 % dans les centres urbains d'un million d'habitants et plus. Cette tendance s'observe également dans les taux de non-réponse à la collecte.

- L'analyse des taux de réponse finaux dans les strates d'aires géographiques à revenu élevé et à faible revenu provenant du plan d'échantillonnage révèle que le taux de non-réponse dans les strates à revenu élevé (42,2 %) est plus élevé que ceux observés dans les strates régulières (27,3 %) et dans les strates à faible revenu (27,3 %). Le taux de refus des strates à revenu élevé (30,5 %) est plus du double de celui des strates à faible revenu (13,3 %) et près du double de celui des strates régulières (17,4 %).

Les erreurs de couverture

- On observe un sous-dénombrement des ménages de 8,5 % à l'échelle nationale. On observe aussi un sous-dénombrement des ménages pour chacune des provinces et chacun des territoires, les taux variant de 4,9 % à 14,9 %. C'est au Yukon et en Colombie-Britannique que le sous-dénombrement des ménages est le plus élevé.

- On observe un sous-dénombrement des personnes de 11,3 % à l'échelle nationale. On observe aussi un sous-dénombrement des personnes pour chacune des provinces et chacun des territoires, les taux variant de 6,6 % à 22,7 %. C'est au Yukon et aux Territoires du Nord-Ouest que le sous-dénombrement des personnes est le plus élevé.

- À l'échelle nationale, on constate qu'il y a toujours un sous-dénombrement net quelque soit le groupe d'âge. À l'exception de la catégorie des 65 à 69 ans, les taux de sous-dénombrement chez les enfants (0 à 6 ans et 7 à 17 ans) sont inférieurs à ceux observés pour les adultes. Le taux de sous-dénombrement pour l'ensemble des enfants est de 5,5 %, alors qu'il est de 13,0 % pour les adultes.

Les erreurs de réponse

- Les erreurs de réponse comprennent, entre autres, les erreurs de rappel, l'erreur télescopique et les erreurs dues aux réponses par procuration. Dans l'Enquête sur les dépenses des ménages (EDM), le fardeau imposé au répondant, étant donné la longueur de l'entrevue, peut entraîner la fatigue du répondant et avoir un impact sur la qualité des données. Le temps total d'entrevue varie selon les caractéristiques des ménages et peut être de plus de cinq heures pour certains ménages. Le temps moyen de l'entrevue était d'une heure et quarante-six minutes.

Les erreurs de traitement reliées à l'imputation

i) Des variables de dépenses

- Il a fallu imputer au moins une variable de dépenses (excluant les dépenses vestimentaires et les dépenses de la section sur l'impôts personnels, sécurité et dons en argent) pour 12,8 % des ménages. Pour la majorité d'entre eux, seulement une ou deux variables parmi les 229 variables de dépenses ont été imputées. À l'échelle provinciale et territoriale, les taux d'imputation varient entre un minimum de 6,6 % pour le Québec et un maximum de 18,2% pour Terre-Neuve-et-Labrador. En excluant les paiements hypothécaires réguliers et les primes d'assurance hypothécaire, le taux d'imputation est de 8,3 %, ce qui est comparable aux taux obtenus les années précédentes. À elle seule, la variable représentant les primes d'assurance hypothécaire nécessite une imputation pour 15,6 % des ménages ayant déclaré des hypothèques sur les logements dont ils étaient propriétaires et occupants.

- Près de 19 % des individus ont nécessité l'imputation de variables sur les dépenses vestimentaires mais pour la très grande majorité, le total était fourni par le répondant et seules les composantes ont été imputées.

- Environ 3 % des personnes âgées de 15 ans et plus ont nécessité l'imputation d'au moins une des variables de la section sur l'impôts personnels, sécurité et dons en argent.

ii) Des variables de revenu

- Il a fallu imputer au moins une variable de revenu pour moins de 5 % des individus âgés de 15 ans et plus. Pour 70 % d'entre eux, le revenu total était fourni par le répondant mais toutes les composantes (sources de revenu) ont été imputées.

iii) Des variables catégoriques

- Il a fallu imputer au moins une variable catégorique pour 6,4 % des ménages. Pour près de 75 % d'entre eux, seulement une variable a été imputée. À l'échelle provinciale et territoriale, les taux d'imputation varient entre un minimum de 2,8 % pour l'Île-du-Prince-Édouard et un maximum de 10,7 % pour la Saskatchewan. Les variables catégoriques qui sont imputées se trouvent aux sections suivantes du questionnaire: Caractéristiques du logements; Équipement associé au logement; Mode d'occupation du logement ; et Tabac et dépenses diverses, pour les variables se rapportant aux achats par le biais de vente directe.

Introduction

L'Enquête sur les dépenses des ménages (EDM) est une enquête annuelle qui collecte les dépenses et les revenus des ménages à l'aide d'entrevues personnelles. L'échantillon de l'EDM 2003 est composé de 23 869 ménages[1] répartis dans les 10 provinces et les trois territoires. La collecte est effectuée au cours des mois de janvier, février et mars et les revenus et dépenses sont obtenus pour la période du 1er janvier au 31 décembre de l'année précédente. À la suite d'un remaniement en 1997, cette enquête remplace l'Enquête périodique sur les dépenses des familles et l'Enquête sur l'équipement ménager (avec ajustements aux questionnaires et aux échantillons).

L'EDM, comme toutes les enquêtes, est sujette aux erreurs et ce malgré toutes les précautions prises aux différentes étapes de l'enquête pour les contrôler. Quoiqu'il n'existe pas de mesure exhaustive de la qualité des données d'une enquête, certaines mesures de qualité produites aux différentes étapes de l'enquête peuvent fournir à l'utilisateur de l'information pertinente pour une bonne interprétation des données.

Ce document vise donc à présenter les indicateurs de qualité produits pour l'enquête sur les dépenses des ménages de 2003. On y trouve les indicateurs de qualité usuels généralement utiles aux utilisateurs pour l'interprétation des données tels que les coefficients de variation, les taux de réponse et de non-réponse, les taux de glissement et les taux d'imputation.

Les indicateurs de qualité ont été classés selon les principaux types d'erreur que l'on retrouve dans une enquête. Les erreurs d'échantillonnage, c'est-à-dire les erreurs dues au fait que les inférences tirées au sujet de l'ensemble de la population sont fondées sur des renseignements recueillis auprès d'un échantillon de la population et non pas auprès de toute la population, sont présentées dans la section 1. Les sections suivantes couvrent les erreurs non dues à l'échantillonnage. La non-réponse et les erreurs de couverture sont d'abord discutées dans les sections 2 et 3. Les erreurs de réponse et les erreurs de traitement sont traitées dans les sections 4 et 5 respectivement.

Ce document est axé sur la qualité des données. Pour une description détaillée de la méthodologie de l'enquête, on peut consulter la référence [1].

1. Au départ, l'échantillon compte 27 671 logements desquels on doit identifier et enlever les logements inadmissibles (voir section 2.1) pour en arriver à 23 869 ménages auprès desquels on collecte les dépenses et les revenus.

1. Les erreurs d'échantillonnage

Les erreurs d'échantillonnage découlent du fait que les inférences que l'on tire au sujet de l'ensemble de la population à partir de l'enquête sont fondées sur l'information que l'on a recueillie auprès d'un échantillon de la population et non pas auprès de toute la population. Outre le plan de sondage et la méthode d'estimation qui ont été appliqués pour l'enquête sur les dépenses des ménages, la taille d'échantillon ainsi que la variabilité de chaque caractéristique sont des facteurs déterminants de l'erreur d'échantillonnage. Les caractéristiques qui sont rares ou qui sont distribuées de façon très différente dans la population auront une erreur d'échantillonnage plus grande que les caractéristiques qu'on observe plus fréquemment ou qui sont plus homogènes dans la population.

1.1 Les mesures de l'erreur d'échantillonnage

L'erreur-type est une mesure standard de l'erreur d'échantillonnage. L'erreur-type correspond au degré de variation de l'estimation considérant qu'un échantillon particulier a été choisi, plutôt qu'un autre, parmi tous les échantillons possibles de même taille sous le même plan de sondage. Comme l'EDM utilise un plan d'échantillonnage et une méthode d'estimation complexes, on estime l'erreur-type à partir d'une méthode de rééchantillonnage appelée le bootstrap. Jusqu'à l'année de référence 2002, l'EDM utilisait la méthode de rééchantillonnage du jackknife afin de produire les estimations de l'erreur type. Il a été décidé d'utiliser la méthode du bootstrap à compter de l'EDM de 2003 principalement en raison du fait que la Division de la statistique du revenu (DSR) allait diffuser les médianes des dépenses et requérait donc les coefficients de variation de celles-ci. La méthode du bootstrap permet l'estimation de la variance de statistiques non lisses comme les quantiles. Pour plus de détails sur cette méthode, voir la référence [2].

Le coefficient de variation (CV) est également une mesure de fiabilité de l'estimation fréquemment utilisée. Il exprime tout simplement l'erreur-type en pourcentage de l'estimation. Ainsi, si on obtient une estimation Y pour une certaine caractéristique et que SE correspond à l'erreur-type estimée, le CV sera (SE/Y) x 100.

Finalement, l'erreur-type ou le coefficient de variation peuvent être utilisés pour dériver une autre mesure de précision des estimations, l'intervalle de confiance. Cette mesure indique le niveau de confiance selon lequel la valeur réelle dans la population pour une caractéristique qu'on a observée se trouve à l'intérieur de certaines limites. Un intervalle avec un niveau de confiance de 95 % correspond à l'estimation obtenue à partir de l'échantillon ± 2 erreur-type : (Y ± 2 SE).[2] Cela signifie que si on répétait l'échantillonnage un grand nombre de fois, chaque échantillon fournirait un intervalle différent et 95 % des intervalles contiendraient la vraie valeur de la caractéristique. De façon similaire, si on répétait l'échantillonnage, l'intervalle Y± SE contiendrait la vraie valeur dans 68 % des cas.

---

2. L'intervalle de confiance se calcule directement à partir du CV de façon similaire, soit Y ± 2 (CV x Y)/100.

1.2 Les coefficients de variation

Des estimations des coefficients de variation sont calculées pour les estimations de plusieurs caractéristiques collectées dans l'EDM. Les CV pour les estimations de la moyenne des dépenses par ménage (pour les catégories de dépenses détaillées), ainsi que pour les caractéristiques des logements et l'équipement ménager, sont disponibles à l'échelle nationale, provinciale et territoriale dans la publication *Guide de l'utilisateur — Enquête sur les dépenses des ménages* (référence [3]).

On doit noter que les estimations de CV ne tiennent pas compte du fait que certaines données ont été imputées; par conséquent, les CV présentés peuvent sous-estimer les valeurs réelles. Pour la plupart des variables, le taux d'imputation est peu élevé (voir section 5) et les CV fournis représentent une bonne estimation des vrais CV. Cependant, il est important de tenir compte à la fois du CV et du taux d'imputation si on s'intéresse à la fiabilité de dépenses détaillées ayant un taux d'imputation élevé.

Le tableau 1.1 donne un aperçu des CV des estimations des moyennes par ménage à l'échelle provinciale et territoriale ainsi qu'à l'échelle nationale pour l'estimation de quelques-unes des catégories de dépenses sommaires et pour le revenu.

Tableau 1.1
Coefficients de variation (%) par province et territoire ainsi qu'à l'échelle nationale pour l'estimation de la moyenne des dépenses par ménage pour quelques catégories de dépenses sommaires et pour l'estimation du revenu moyen

Catégories de dépenses sommaires	Can.	T.-N.-L.	Î.-P.-É.	N.-É.	N.-B.	Qc	Ont.	Man.	Sask.	Alb.	C.-B.	Yn	T.N.-O.	Nt
Dépenses totales	0,7	1,6	2,3	1,6	1,2	1,7	1,4	1,4	1,5	1,3	1,5	3,6	3,9	5,9
Dépenses de consommation	0,7	1,5	2,2	1,4	1,3	1,3	1,3	1,5	1,5	1,4	1,4	3,4	3,9	5,8
Alimentation	0,6	1,3	2,2	1,3	1,3	0,9	1,2	1,5	1,6	1,4	1,4	3,8	3,5	2,9
Logement	0,9	2,3	2,7	1,6	1,8	1,4	1,7	2,1	1,5	1,9	1,6	4,1	5,1	7,2
Entretien ménager	1,0	1,6	3,5	2,6	2,0	1,6	2,1	1,9	1,9	2,3	2,1	4,7	4,1	7,1
Ameublement	1,7	3,5	5,5	4,1	3,4	3,4	3,3	3,8	4,3	3,5	4,2	10,5	9,2	12,4
Habillement	1,3	2,5	3,5	3,0	2,7	2,0	2,5	2,5	3,1	2,8	3,4	10,1	6,5	8,2
Transport	1,5	3,7	4,7	3,6	3,0	3,3	2,8	4,6	3,7	3,7	3,3	7,2	10,4	19,7
Soins de santé	1,3	3,0	3,5	3,7	3,2	2,0	3,3	4,0	3,8	2,5	2,8	7,8	9,9	19,7
Soins personnels	1,0	2,2	3,6	2,1	2,4	1,6	2,0	2,2	2,2	2,8	2,5	9,9	4,6	8,2
Loisirs	1,7	3,8	6,5	3,1	4,5	3,0	3,4	3,5	3,7	3,3	3,9	7,7	7,3	9,2
Lecture et autres imprimés	1,7	4,3	5,1	3,8	4,0	2,9	3,6	4,0	3,3	4,1	3,7	7,6	8,0	19,0
Éducation	3,0	7,5	11,0	8,3	8,6	4,3	5,4	7,5	6,9	7,3	6,7	12,4	19,6	29,7
Tabac, boissons alcoolisées	1,8	3,6	6,9	4,1	4,8	2,7	3,5	4,8	4,0	4,5	4,5	8,4	8,2	8,1
Jeux de hasard (net)	4,1	6,4	13,8	8,0	9,6	6,3	7,7	8,2	7,4	13,3	13,4	14,4	24,3	20,4
Dépenses diverses	2,9	6,0	28,1	5,1	5,4	4,2	6,0	6,0	6,4	8,2	6,5	10,9	7,6	17,2
Impôts personnels	1,7	3,7	4,5	2,8	2,2	3,4	3,2	2,6	2,9	2,5	2,6	6,3	5,2	9,7
Assurances individuelles et cotisations de retraite	1,2	3,1	2,9	9,5	1,9	2,5	2,3	3,2	2,2	2,1	2,0	6,9	5,0	6,7
Dons et contributions	6,0	8,3	14,9	9,3	7,9	9,3	10,8	11,5	6,3	7,6	18,6	15,1	15,1	16,5
Revenu	0,7	1,4	2,2	1,5	1,1	1,6	1,5	1,3	1,5	1,1	1,4	3,9	4,6	6,0

Les coefficients de variation de l'estimation de la moyenne des dépenses totales par ménage varient entre 1,2 % et 2,3 % selon les provinces et il est de 0,7 % à l'échelle nationale. Les CV sont plus élevés dans les territoires, soit 3,6 % au Yukon, 3,9 % dans les Territoires du Nord-Ouest et de 5,9 % au Nunavut.

Pour les différentes catégories de dépenses sommaires, les CV à l'échelle nationale sont inférieurs ou égaux à 1,7 % à l'exception des dépenses dans les catégories suivantes: éducation, jeux de hasard, dépenses diverses ainsi que dons en argent et contributions. Ces catégories de dépenses représentent respectivement 1,6 %, 0,4 %, 1,5 % et 2,5 % du total des dépenses (données non présentées). De plus, si on fait exception de ces catégories, les CV sont généralement inférieurs ou égaux à 5 % à l'échelle provinciale. À l'exception de ces mêmes catégories, les CV dans les territoires sont pour la plupart inférieurs à 11 %. Également, la taille de l'échantillon étant moindre dans les territoires, les CV ont tendance à être plus élevés que ceux des provinces.

Le tableau 1.2 donne un aperçu des CV pour les caractéristiques des logements et l'équipement ménager à l'échelle provinciale et territoriale ainsi qu'à l'échelle nationale pour l'estimation de quelques-unes des catégories.

Tableau 1.2
Coefficients de variation (%) par province et territoire ainsi qu'à l'échelle nationale pour quelques catégories des caractéristiques des logements et l'équipement ménager

Catégories	Can.	T.-N.-L.	Î.-P.-É.	N.-É.	N.-B.	Qc	Ont.	Man.	Sask.	Alb.	C.-B.	Yn	T.N.-O.	Nt
Propriétaire	0,9	1,7	3,3	2,0	1,8	1,7	1,9	1,9	1,8	1,9	1,9	6,6	10,9	15,1
Locataire	1,7	5,6	8,6	5,0	5,2	2,2	4,0	4,7	5,0	4,8	3,3	10,8	16,4	8,5
Machine à laver	0,6	0,9	2,1	1,5	1,3	0,8	1,5	1,6	1,2	1,1	1,3	4,7	5,3	4,9
Sécheuse	0,6	1,1	2,3	1,5	1,3	0,9	1,6	1,6	1,1	1,2	1,5	4,4	7,0	5,5
Lave-vaisselle	1,1	3,8	4,7	3,5	3,4	1,9	2,5	2,7	2,6	2,0	1,8	7,2	8,0	12,4
Congélateur	1,0	1,4	3,0	2,3	1,8	2,0	2,1	1,7	1,5	2,3	2,2	5,6	6,1	7,9
Four à micro-ondes	0,3	0,6	1,1	0,7	0,6	0,6	0,6	0,7	0,6	0,6	1,0	2,1	4,3	4,7
Téléphone cellulaire	1,1	2,9	5,2	2,8	3,7	2,4	2,0	2,8	2,8	2,0	2,1	12,2	8,0	24,6
Lecteur de disques compacts	0,6	1,5	2,5	1,5	1,7	1,2	1,3	1,7	1,6	1,3	1,4	4,4	3,5	6,0
Télédistribution	1,0	2,4	5,0	2,7	2,9	1,9	2,0	2,7	3,0	2,6	1,6	10,4	6,2	6,8
Antenne parabolique	2,4	5,0	7,8	5,6	5,0	4,2	5,5	4,7	4,4	4,8	5,7	11,7	12,0	16,4
Lecteur DVD	1,1	2,9	4,7	2,4	2,9	2,1	2,2	2,3	2,6	2,1	2,6	5,4	5,0	8,2
Ordinateur personnel	0,8	2,5	3,8	2,0	2,4	1,6	1,5	2,0	1,8	1,6	1,6	4,8	6,8	7,9
Connexion tél. régulière à un ordinateur (Modem)	2,4	5,4	9,5	6,2	4,6	4,1	4,4	7,0	7,1	7,4	6,8	15,3	17,4	11,2
Connexion tél. haute vitesse à un ordinateur	2,7	9,4	12,0	5,6	8,5	5,1	5,7	6,7	5,2	5,3	5,5	9,2	12,8	40,0
Utilisation d'Internet (maison)	0,9	3,2	4,9	2,4	2,8	2,0	1,9	2,7	2,4	2,1	2,1	6,7	7,0	10,8
Véhicules possédés (un)	1,3	2,8	6,2	3,7	3,4	2,4	2,9	3,1	3,3	3,1	2,9	9,6	5,6	14,3
Véhicules possédés (2 ou plus)	1,4	4,4	4,9	2,9	3,5	2,9	3,1	2,8	3,2	2,4	2,7	7,1	10,2	22,3

Les coefficients de variation pour les caractéristiques des logements et l'équipement ménager sont généralement inférieurs à 5 % à l'échelle provinciale sauf pour les catégories : *locataire, antenne parabolique, connexion téléphonique régulière à un ordinateur (Modem) et connexion téléphonique haute vitesse à un ordinateur.* Les CV sont plus élevés dans les territoires où l'on retrouve parfois une proportion moindre des équipements. En outre, la taille de l'échantillon étant moindre dans les territoires, les CV on tendance à être plus élevé que ceux des provinces.

Les CV pour les caractéristiques des logements et l'équipement ménager à l'échelle nationale sont inférieurs ou égaux à 1,7 % à l'exception des catégories suivantes : *antenne parabolique, connexion téléphonique régulière et connexion téléphonique haute vitesse à un ordinateur.* On retrouve une proportion moindre

de ménages possédant de tels équipements pour ces trois catégories. Cette proportion représente respectivement 22,6 %, 21,2 % et 17,3 % à l'échelle nationale (données non présentées).

1.3 Modèle pour dériver une approximation du CV

Des estimations pour différents domaines d'intérêt (par ex., par quintile de revenu) sont disponibles pour les catégories de dépenses sommaires dans la publication *Les habitudes de dépenses au Canada* (référence [4]). Des estimations pour différents domaines d'intérêt pour les catégories de dépenses détaillées sont également disponibles sur demande auprès de la Division de la statistique du revenu. (Pour plus de détails sur les tableaux disponibles auprès de la Division de la statistique du revenu, voir les références [3] ou [4].) Pour des raisons opérationnelles, il n'est pas possible de produire les CV pour tous les différents niveaux d'agrégation qui pourraient intéresser les utilisateurs.

1.3.1 Approximation du CV pour les estimations des domaines

Il est toutefois possible de calculer une approximation du CV en utilisant une relation entre le nombre de ménages de l'échantillon qui ont déclaré des dépenses pour une catégorie et le CV à un niveau agrégé. Cette relation, basée sur la tendance du CV à croître proportionnellement à une diminution de la racine carrée du nombre de ménages déclarant une dépense, est illustrée ci-après.

Formule d'approximation du CV pour un domaine (un sous-groupe de la population)

Si CV(Y) représente le CV pour l'estimation de la moyenne par ménage d'une certaine caractéristique pour toute la population, alors on peut calculer une approximation du CV de l'estimation de cette caractéristique pour un domaine (que l'on peut considérer comme un sous-groupe de la population tel qu'un type de ménage, un quintile de revenu, un niveau d'urbanisation) à partir de l'équation suivante :

$$CV\ (Y_d) = CV\ (Y) \times \sqrt{\frac{nP}{n_d P_d}}$$

où

n : le nombre de ménages dans l'échantillon
P : l'estimation de la proportion des ménages déclarant une valeur > 0 pour cette caractéristique dans la population
n_d : le nombre de ménages de l'échantillon dans le domaine d
P_d : l'estimation de la proportion des ménages déclarant une valeur > 0 pour cette caractéristique dans le domaine d

Généralement on utilise le CV, la taille *n* et la proportion *P* à l'échelle nationale pour calculer les approximations pour les différents domaines. Dans le cas où on cherche à calculer une approximation du CV pour un domaine entièrement contenu dans une seule province (par ex. région métropolitaine), il est préférable

d'utiliser ces valeurs à l'échelle provinciale puisque les CV provinciaux sont publiés pour l'EDM de 2003 (référence [3]). Il est important de se rappeler que la valeur du CV obtenue par cette approche n'est qu'une approximation du CV.

1.3.2 Approximation du CV à partir du fichier de microdonnées

Les utilisateurs du fichier de microdonnées peuvent se servir d'une autre approche pour dériver une approximation du CV des estimations, qui sera généralement plus performante que celle présentée dans la section précédente pour les CV des catégories de dépenses détaillées. Cette approche est décrite en détails dans la documentation accompagnant le fichier de microdonnées de 2003. Elle est utilisable seulement à partir du fichier de microdonnées puisqu'il est nécessaire d'avoir les données et les poids de chaque ménage pour calculer cette approximation.

Le document sur la qualité des données de l'enquête de 1997 renferme des résultats de l'évaluation de la performance de ces deux méthodes d'approximation du CV.

1.4 Suppression des données non fiables dans les tableaux d'estimations

Comme le coefficient de variation est un indicateur de la fiabilité des données, on aimerait l'utiliser pour déterminer si les estimations devraient être publiées ou non. On considère que les estimations dont le CV est estimé à plus de 33 % ne sont pas suffisamment fiables pour être publiées. Toutefois les estimations des CV ne sont pas calculées pour une grande partie des estimations publiées, la règle de suppression pour les estimations de dépenses est donc basée sur le nombre de ménages qui déclarent une valeur supérieure à zéro.[3]

On peut démontrer que les CV sont en général inférieurs à 33 % si le nombre de ménages qui déclarent une dépense est supérieur à 30. Comme il s'agit d'une règle approximative, certaines estimations peuvent être publiées même si le CV est supérieur à 33 % et certaines estimations ne seront pas publiées malgré un CV inférieur à 33 %. Le document sur la qualité des données de l'EDM 1997 donne les résultats de l'évaluation des risques d'erreurs de l'utilisation de la règle de suppression.

2. La non-réponse

Les erreurs dues à la non-réponse découlent du fait que certains répondants potentiels ne fournissent pas l'information nécessaire ou que cette information s'avère inutilisable. Lorsque le répondant a omis de répondre à certaines questions seulement, on parle alors de non-réponse partielle. Dans ce cas, les données manquantes sont imputées. Les erreurs liées à l'imputation sont présentées dans la section 5 portant sur les erreurs de traitement. Dans la

3. En pratique, on utilise l'estimation de la proportion des ménages déclarant une dépense que l'on multiplie par la taille d'échantillon.

présente section, la non-réponse englobe la non-réponse à la collecte, due principalement à l'impossibilité de contacter le ménage ou au refus des membres du ménage de participer à l'enquête, que ce soit partiellement ou complètement, ainsi que les ménages pour lesquels les données ont été collectées mais sont inutilisables.

Le principal impact de la non-réponse sur la qualité des données est qu'elle peut induire un biais dans les estimations si les caractéristiques des répondants et des non-répondants diffèrent et que cette différence a un impact sur les caractéristiques étudiées. Les taux de non-réponse peuvent être calculés facilement mais ils n'ont qu'une valeur indicative à l'égard de la qualité des données car ils ne permettent pas de mesurer l'importance du biais associé aux estimations. L'ampleur de la non-réponse peut être considérée comme une évaluation des risques de biais dans les estimations.

2.1 Le taux de réponse, les taux de non-réponse et les taux de vacance

Dans l'EDM, comme les unités sélectionnées sont des logements, les intervieweurs doivent d'abord identifier les logements inadmissibles, c'est-à-dire les logements occupés par des personnes ne faisant pas partie de la population cible, les logements qui n'existent plus (démoli, maison mobile déplacée ou logement converti en entreprise) et les logements vacants (inoccupés, saisonniers ou en construction).

Parmi les logements admissibles, on évalue ensuite la proportion des ménages qui n'ont pas répondu à l'enquête, qu'on appelle le taux de non-réponse à la collecte. Ces derniers comprennent les ménages qui ont refusé de participer à l'enquête et les ménages où il a été impossible d'établir un contact avec les répondants parce qu'ils étaient absents ou encore à cause de circonstances spéciales (problème de langue, maladie ou décès).

Toujours parmi les logements admissibles, on détermine également le taux de données inutilisables. Les données inutilisables correspondent au nombre de ménages pour lesquels le questionnaire était au moins partiellement complet mais qui ont été rejetés lors du traitement des données. Il existe deux causes principales de rejet. D'abord lorsqu'une partie importante des questions sur le revenu ou des questions sur les dépenses a été laissée sans réponse, le questionnaire est classé incomplet et n'est pas utilisé. L'autre source de rejet correspond aux questionnaires pour lesquels la différence entre les entrées (revenu et autres sources d'argent du ménage) et les déboursés (dépenses et variation nette des actifs et passifs) est supérieure à 20 %. Ces questionnaires sont également exclus de l'estimation et considérés comme de la non-réponse.

Il est à noter que tous les taux de la présente section sont non pondérés. Pour l'Enquête sur les dépenses des ménages de 2003, le taux de réponse final est de 72,3 %. Le tableau 2.1a présente le taux de réponse final ainsi que la taille de l'échantillon (ménages admissibles) ventilée selon les refus, les non-contacts, les données inutilisables et les données utilisables. Ce taux est fourni tant à l'échelle nationale que provinciale et territoriale.

Cette année, un échantillon supplémentaire d'environ 2 000 ménages au Québec a été financé par le Ministère des finances du Québec afin de mieux répondre aux besoins analytiques de celui-ci. Cet échantillon a été sélectionné d'une liste de logements selon un plan stratifié à deux degrés d'échantillonnage. La base liste, qui est construite à partir du Registre des adresses de Statistique Canada, est constituée des logements d'un certain nombre d'aires de diffusion du Recensement de 2001. Pour une description détaillée du plan de sondage de l'échantillon supplémentaire, on peut consulter la référence [6].

Tableau 2.1a
Taille de l'échantillon et taux de réponse (%) par province et territoire ainsi qu'à l'échelle nationale

Province ou territoire	Ménages admissibles	Non contactés	Ayant refusé de participer	Inutilisables	Utilisables	Taux de réponse final (à l'estimation)[1] %
Canada	23 869	1 647	4 234	723	17 265	72,3
Terre-Neuve-et-Labrador	1 772	134	198	69	1 371	77,4
Île-du-Prince-Édouard	781	52	121	27	581	74,4
Nouvelle-Écosse	2 048	150	347	132	1 419	69,3
Nouveau-Brunswick	1 845	98	303	118	1 326	71,9
Québec	4 817	360	927	68	3 462	71,9
Ontario	3 149	282	787	103	1 977	62,8
Manitoba	1 887	104	312	49	1 422	75,4
Saskatchewan	1 837	72	280	77	1 408	76,6
Alberta	2 087	128	336	18	1 605	76,9
Colombie-Britannique	2 580	205	500	45	1 830	70,9
Yukon	418	28	74	9	307	73,4
Territoires du Nord-Ouest	410	21	42	8	339	82,7
Nunavut	238	13	7	-	218	91,6

1. Utilisables/ménages admissibles x 100

Le tableau 2.1b présente le taux de non-réponse final, le taux de non-réponse à la collecte, ventilé selon les refus et les non-contacts ainsi que le taux de données inutilisables, ventilé selon les incomplets et les non balancés. On y trouve également le taux de vacance. Ces taux sont fournis tant à l'échelle nationale que provinciale et territoriale.

Notons que les taux de vacance présentés aux tableaux de la section 2 incluent les logements vacants (inoccupés, saisonniers ou en construction) ainsi que les logements qui n'existent plus (démoli, maison mobile déplacée ou logement converti en entreprise).

Tableau 2.1b
Taux de non-réponse (%) et taux de vacance (%) par province et territoire ainsi qu'à l'échelle nationale

Province ou territoire	Taux de vacance	Taux de non-réponse à la collecte			Taux de données Inutilisables			Taux de non-réponse final (à l'estimation)
		Total	Pas de contact	Refus	Total	Incomplet	Non équilibré	
Canada	11,0	24,6	6,9	17,7	3,0	1,3	1,7	27,7
Terre-Neuve-et-Labrador	15,4	18,7	7,6	11,2	3,9	1,8	2,1	22,6
Île-du-Prince-Édouard	18,1	22,2	6,7	15,5	3,5	1,7	1,8	25,6
Nouvelle-Écosse	13,8	24,3	7,3	16,9	6,4	1,2	5,2	30,7
Nouveau-Brunswick	13,7	21,7	5,3	16,4	6,4	1,9	4,5	28,1
Québec	7,3	26,7	7,5	19,2	1,4	1,2	0,2	28,1
Ontario	8,2	33,9	9,0	25,0	3,3	1,9	1,4	37,2
Manitoba	9,6	22,0	5,5	16,5	2,6	0,7	1,9	24,6
Saskatchewan	15,7	19,2	3,9	15,2	4,2	1,3	2,9	23,4
Alberta	9,0	22,2	6,1	16,1	0,9	0,7	0,1	23,1
Colombie-Britannique	8,9	27,3	7,9	19,4	1,7	1,4	0,4	29,1
Yukon	15,3	24,4	6,7	17,7	2,2	0,2	1,9	26,6
Territoires du Nord-Ouest	12,2	15,4	5,1	10,2	2,0	0,2	1,7	17,3
Nunavut	14,8	8,4	5,5	2,9	0,0	0,0	0,0	8,4

Le taux de non-réponse final au Canada est de 27,7 %. Il est dû aux refus (17,7 %), aux ménages qu'il a été impossible de rejoindre (6,9 %), et finalement aux ménages dont les données étaient inutilisables (3,0 %). Pour presque toutes les provinces, les refus représentent la cause majeure de non-réponse, suivis des non-contacts, puis des données inutilisables. Les seules exceptions sont le Nunavut pour lequel le taux de refus est inférieur au taux de non-contacts ainsi que les provinces du Nouveau-Brunswick et de la Saskatchewan pour lesquelles la proportion de données inutilisables est supérieure à la proportion de non-contacts.

Les taux de non-réponse finaux varient selon les provinces. C'est au Nunavut que l'on observe le taux de non-réponse le plus bas, soit de 8,4 %. C'est aussi dans ce territoire que la proportion de refus est la plus faible (2,9 %). De plus, au Nunavut, toutes les données recueillies étaient utilisables, ce qui veut dire que la non-réponse finale est attribuable seulement à la non-réponse obtenue lors de la collecte. Les taux de non-réponse du Nunavut et des Territoires du Nord-Ouest sont inférieurs à 20 %, tandis que les taux sont supérieurs à 30 % en Nouvelle-Écosse et en Ontario. Le taux de non-réponse final plus élevé en Nouvelle-Écosse est en partie attribuable à un taux plus élevé de questionnaires non équilibrés (5,2 %). Le taux de non-réponse de l'Ontario est particulièrement élevé atteignant 37,2 %. C'est aussi dans cette province que l'on trouve le plus haut taux de non-contacts (9,0 %) et de refus (25,0 %).

Le taux de vacance est présenté au tableau 2.1b, mais on doit considérer que les logements vacants ne contribuent pas au biais de l'échantillon dans la mesure où ils sont identifiés correctement. En analysant les taux de vacance, on décèle les problèmes d'identification des logements liés à la collecte. Le taux de vacance de l'EDM de 2003 est de 11,0 %.

2.2 La non-réponse selon le niveau d'urbanisation

La non-réponse varie selon le niveau d'urbanisation. Les divers taux à l'échelle nationale sont présentés par niveau d'urbanisation dans le tableau 2.2.[4]

Tableau 2.2
Taux de non-réponse (%) et taux de vacance (%) par niveau d'urbanisation

Catégorie d'urbanisation	Taux de vacance	Taux de non-réponse à la collecte			Taux de données inutilisables			Taux de non-réponse final (à l'estimation)
		Total	Pas de contact	Refus	Total	Incomplet	Non équilibré	
Urbain								
1 000 000 ou plus	4,8	31,8	9,4	22,4	2,0	1,5	0,5	33,8
500 000 à 999 999	5,7	25,3	6,3	19,0	1,6	0,8	0,7	26,9
250 000 à 499 999	5,4	30,1	8,2	21,9	6,2	1,2	5,0	36,3
100 000 à 249 999	7,6	24,0	6,5	17,5	4,5	1,3	3,2	28,5
30 000 à 99 999	6,7	26,4	7,1	19,4	3,4	1,7	1,7	29,8
Moins de 30 000	10,6	20,0	5,8	14,2	2,7	1,2	1,5	22,7
Rural	23,1	18,9	5,4	13,5	3,4	1,3	2,0	22,3
Total	11,0	24,6	6,9	17,7	3,0	1,3	1,7	27,7

Le taux de non-réponse final augmente généralement avec le niveau d'urbanisation. Selon les résultats du tableau 2.2, il n'y a que le groupe des 500 000 à 999 999, celui des 100 000 à 249 999 et, dans une moindre mesure, le groupe des 1 000 000 ou plus, qui ne suivent pas cette tendance. Pour le groupe des 500 000 à 999 999, ceci est dû dans une certaine mesure au fait que c'est pour celui-ci que l'on trouve le plus faible taux de données inutilisables (1,6 %). Pour le groupe des 100 000 à 249 999, ceci est dû à un taux de refus (17,5 %) plus faible que pour les autres régions urbaines de plus de 30 000 habitants. Le taux de non-réponse final de 36,3 % de la catégorie d'urbanisation «250 000 à 499 999» est dû à la fois à la non-réponse obtenue lors de la collecte (30,1 %), laquelle est due en partie à celle obtenue en Ontario (38.1 %, donnée non présentée), ainsi qu'au taux de données inutilisables (6,2 %), lequel est dû en partie à celui obtenu en Nouvelle-Écosse (9,8 %, donnée non présentée).

Le taux de non-réponse à la collecte a lui aussi tendance à croître avec le niveau d'urbanisation. Il y a un écart de près de 12 % entre les catégories d'urbanisation

4. Des tableaux portant sur les taux de non-réponse selon le niveau d'urbanisation par province sont disponibles sur demande auprès de la Division des méthodes d'enquêtes auprès des ménages.

«Moins de 30 000» et «1 000 000 ou plus». Les refus comptent pour plus de 60 % de la non-réponse totale à tous les niveaux d'urbanisation. Bien que la catégorie d'urbanisation «500 000 à 999 999» possède le plus faible taux de non-réponse totale pour les régions urbaines de 30 000 habitants et plus, c'est pour celle-ci que la proportion de non-réponse totale due aux refus des ménages de participer à l'enquête est la plus élevée (70,6 %). C'est dans la catégorie d'urbanisation «1 000 000 ou plus» que l'on retrouve le plus haut taux de non-contacts (9,4 %) et de refus (22,4 %).

En examinant les taux de vacance par niveau d'urbanisation, il ressort que le taux de vacance est deux fois plus élevé en région rurale (23,1 %) que dans les régions urbaines à faible population (10,6 %). Ces dernières régions ont aussi un taux de vacance supérieur à celui des régions urbaines à plus forte population. Ce phénomène s'observe également dans l'EPA et s'explique sans doute par un plus grand nombre de logements saisonniers en milieu rural. Ceci explique entre autre pourquoi le taux de vacance est plus élevé dans les provinces de l'Atlantique, tel qu'il est illustré dans le tableau 2.1b, et surtout à l'Île-du-Prince-Édouard puisqu'on y observe une forte proportion de logements ruraux.

2.3 La non-réponse selon les strates de revenu

Il est impossible de comparer le taux de réponse selon le revenu car cette information n'est pas accessible pour les non-répondants. Toutefois, le plan d'échantillonnage de l'EPA, utilisé pour l'EDM, a été conçu de sorte à former, dans neuf grandes villes, des strates d'aires géographiques où le revenu moyen des ménages excède 100 000 $, et dans sept grandes villes, des strates composées d'appartements habités par des ménages ayant un revenu moyen inférieur à 20 000 $. Même si le nombre de telles strates est petit et qu'il compte pour seulement un petit nombre de logements dans l'échantillon de l'EDM (environ 580 pour les strates de revenus élevés et 160 pour les strates de revenus faibles, soit moins de 3 % de l'échantillon), la comparaison des taux de non-réponse dans ces deux groupes par rapport à l'ensemble des autres strates est révélatrice. Le tableau 2.3 présente ces résultats. Il est à noter que les résultats de ce tableau excluent l'échantillon supplémentaire de la province de Québec. Puisque l'échantillon supplémentaire ne provient pas de la base de sondage de L'EPA, une telle classification de strates (revenu élevé, régulières et revenu faible) n'est pas disponible.

Tableau 2.3
Comparaison des taux (%) de non-réponse et de vacance des strates à revenu élevé et à faible revenu par rapport aux autres strates

Type de strate en fonction du revenu[1]	Taux de vacance	Taux de non-réponse à la collecte			Taux de données inutilisables			Taux de non-réponse final (à l'estimation)
		Total	Pas de contact	Refus	Total	Incomplet	Non équilibré	
Revenu élevé	4,1	39,8	9,4	30,5	2,4	1,5	0,9	42,2
Régulières	11,7	24,1	6,6	17,4	3,2	1,3	1,9	27,3
Revenu faible	3,7	25,2	11,9	13,3	2,1	1,4	0,7	27,3
Total	11,4	24,5	6,7	17,7	3,2	1,3	1,9	27,6

1. Exclut l'échantillon supplémentaire au Québec.

Dans les strates à revenu élevé, le taux de non-réponse final (42,2 %) est de beaucoup supérieur à celui des strates régulières et des strates à faible revenu. Le taux de refus des strates à revenu élevé est de plus de 30 %, ce qui est environ le double de ce qui est observé pour les autres types de strates.

Les ménages des strates à faible revenu ont un taux de non-réponse final identique et un taux de non-réponse à la collecte similaire à ceux des strates régulières. Toutefois les causes de la non-réponse sont différentes pour les deux types de strates. Pour les strates régulières, la non-réponse à la collecte est majoritairement due aux refus tandis que pour les strates à faible revenu, la non-réponse à la collecte se divise à peu près également entre les refus et les non-contacts.

Comme pour les enquêtes de 1997 à 2002, le taux de vacance est plus élevé pour les strates régulières que pour chacun des deux autres types de strate. Dans les strates à revenu élevé et à faible revenu, les taux de vacance sont semblables. Le taux de vacance dans les strates à faible revenu est de 3,7 %, en hausse par rapport au taux de 1,8 % observé en 2002.

2.4 L'ajustement pour la non-réponse

Pour compenser la non-réponse, les poids de l'EDM sont gonflés par l'inverse du taux de réponse pondéré à l'intérieur de certains groupes définis en fonction des différents niveaux d'urbanisation dans chaque province. Les taux pondérés diffèrent des taux présentés dans cette section puisqu'ils tiennent compte du poids de sondage de chaque ménage. Une description algébrique de l'ajustement pour la non-réponse est présentée à l'annexe A.

L'ajustement des poids pour la non-réponse permet de tenir compte des différences au niveau de la non-réponse par niveau d'urbanisation mentionnées dans la section 2.2. Il permettra de réduire le biais dans la mesure où les caractéristiques des répondants et des non-répondants sont similaires pour un même niveau d'urbanisation.

3. Erreurs de couverture

Lors de la conception de l'enquête, on a défini la population visée, qu'on appelle la population cible. Rappelons d'abord la définition de cette population cible pour l'EDM puisqu'une bonne compréhension de la population cible est nécessaire à une bonne interprétation des données de l'enquête. Il est important de préciser qu'à l'exception de l'échantillon supplémentaire sélectionné au Québec cette année, l'EDM utilise la base de sondage de l'enquête sur la population active (EPA).

La population cible

> La population cible correspond aux individus vivant dans les ménages privés. Les pensionnaires d'établissement institutionnel tel que les prisons, les hôpitaux pour malades chroniques, les résidences pour personnes âgées ainsi que les membres d'ordres religieux et d'autres groupes vivant en communauté, les membres des Forces Armées vivant dans les camps militaires et les individus vivant de façon permanente dans les hôtels ou les maisons de chambres sont donc exclus. On exclut aussi les représentants officiels de pays étrangers qui vivent au Canada et leurs familles ainsi que les résidents des réserves indiennes et des terres publiques (à l'exception des Territoires). L'enquête couvre donc près de 98 % de la population dans les 10 provinces. Au Yukon, la couverture de la population est de 88%, celle des Territoires du Nord-Ouest correspond à 92% et la couverture du Nunavut est de 89%.[5]

Nous n'avons pas recueilli de renseignements auprès des personnes qui vivent temporairement loin de leur famille (par exemple, les étudiants d'université) parce que nous obtenons l'information auprès de leur famille, si elle est choisie dans l'échantillon.

Les erreurs de couverture proviennent d'une représentation inadéquate de la population cible à partir des unités de la base de sondage. Certaines unités de la population cible peuvent être omises de la base de sondage, on parle alors d'un sous-dénombrement. D'autres unités qui ne sont pas dans la population cible peuvent être incluses par erreur ou certaines unités peuvent être incluses plus d'une fois, ces unités sont responsables du surdénombrement.

3.1 Le sous-dénombrement et le surdénombrement : les taux de glissement

Dans l'EDM, la sélection de l'échantillon est effectuée en utilisant une liste de logements dans chaque grappe sélectionnée. L'omission de logements lors de la création de la liste, les nouveaux logements qui s'ajoutent entre la création de la liste et la visite des intervieweurs (principalement dans les secteurs en

5. Pour ce qui est de la proportion de ménages, la couverture du Yukon, des Territoires du Nord-Ouest et du Nunavut correspond respectivement à 88%, 93% et 90% des ménages.

développement) ainsi que la classification erronée de logements vacants contribuent au sous-dénombrement. Le fait d'inclure des logements qui ne seraient pas dans les limites de la grappe est une source de surdénombrement. De façon similaire, des erreurs peuvent se glisser lors de la collecte des données, lors de l'identification des personnes qui sont membres du ménage sélectionné. Ces erreurs contribuent également au sous-dénombrement et au surdénombrement.

Une bonne représentation de la population cible est indispensable à la production d'estimations de dépenses réalistes. Le nombre de personnes par ménage est également une caractéristique importante dans l'estimation des dépenses moyennes des ménages. Il est donc nécessaire que l'échantillon, non seulement représente adéquatement les individus de la population cible, mais également la distribution des ménages selon leur taille.

En 1999, une nouvelle méthode de pondération a été introduite utilisant de nouveaux groupes de contrôle. Cette nouvelle méthode nous permet de mieux corriger la représentativité de la population visée en ciblant des groupes d'âge et de sexe mieux délimités que ceux utilisés précédemment et pour lesquels la couverture varie d'un groupe à l'autre.

On observe généralement un sous-dénombrement net du nombre de personnes et du nombre de ménages dans l'EDM, que l'on rectifie par un ajustement des poids en utilisant des données auxiliaires, qui sont basées sur des estimations démographiques post-censitaires. Le taux de glissement (voir annexe A) est une mesure du pourcentage d'écart entre les estimations provenant de ces données auxiliaires et les estimations de l'enquête calculées en utilisant des poids non ajustés avec ces données.[6] Les taux de glissement par groupe d'âge-sexe à l'échelle nationale, provinciale et territoriale sont présentés dans les tableaux 3.1 et 3.2 alors que les taux de glissement selon les tailles de ménages que l'on utilise lors de l'ajustement des poids se trouvent dans le tableau 3.3. Un taux positif correspond à un surdénombrement du nombre de personnes ou de ménages dans l'enquête.

6. On utilise les sous-poids, c'est-à-dire les poids de sondage ajustés pour la non-réponse (voir Annexe A).

Tableau 3.1
Taux de glissement nationaux selon le groupe d'âge-sexe

Taux de glissement national par groupe d'âge-sexe				
		Sexe		
	Âge	Hommes	Femmes	**Total**
Canada[1]	0-6 ans	-1,0	-6,5	-3,7
	7-17 ans	-6,0	-6,8	-6,4
	18-24 ans	-16,9	-14,7	-15,8
	25-34 ans	-24,2	-15,7	-20,0
	35-54 ans	-15,0	-10,1	-12,5
	55-59 ans	-12,2	-8,0	-10,1
	60-64 ans	-10,1	-6,8	-8,4
	65-69 ans	-4,5	-5,2	-4,9
	70 ans et +	-8,9	-7,5	-8,1
	Total	-12,8	-9,8	-11,3

1. Exclut les territoires.

Pour l'EDM de 2003, le taux de sous-dénombrement de la population était 11,3 %. En analysant le tableau 3.1 on constate qu'à l'échelle nationale, il y a toujours un sous-dénombrement net quelque soit le groupe d'âge. À l'exception de la catégorie des 65 à 69 ans, les taux de sous-dénombrement chez les enfants (0 à 6 ans et 7 à 17 ans) sont inférieurs à ceux observés pour les adultes. Le taux de sous-dénombrement pour l'ensemble des enfants est de 5,5 %, alors qu'il est de 13,0 % pour les adultes (données non présentées). Le léger sous-dénombrement observé pour les garçons de 0 à 6 ans est dû en grande partie au surdénombrement obtenu au Québec (1,7 %) et en Ontario (3,6 %) pour ce groupe d'âge-sexe (voir le tableau 3.2). De la même façon, le taux de sous-dénombrement plus faible pour le groupe d'âge des 65 à 69 ans est dû au surdénombrement des femmes de ce groupe d'âge au Québec (11,9 %) ainsi qu'au surdénombrement des hommes de ce groupe d'âge en Ontario (11,2 %) (voir le tableau 3.2).

Les taux les plus élevés à l'échelle nationale sont observés chez les hommes de 25 à 34 ans, chez ceux de 18 à 24 ans, ainsi que chez les femmes de 25 à 34 ans. À l'exception de la catégorie des 65 à 69 ans, le taux de sous-dénombrement chez les femmes est toujours inférieur à celui des hommes.

Tel que mentionné précédemment, l'EDM utilise la base de sondage de l'enquête sur la population active (EPA). Pour une même période, le taux de sous-dénombrement de l'EPA à l'échelle nationale est de 10,7 % (référence [5]), ce qui est légèrement inférieur au taux de 12,6 % de l'EDM observé lorsqu'on se restreint aux personnes de 15 ans et plus (données non présentées).

Tableau 3.2
Taux de glissement pour les provinces et les territoires selon le groupe d'âge-sexe

Taux de glissement par groupe d'âge-sexe														
Sexe	Âge	Terre-Neuve-et-Labrador	Île-du-Prince-Édouard	Nouvelle-Écosse	Nouveau-Brunswick	Québec	Ontario	Manitoba	Saskatchewan	Alberta	Colombie-Britannique	Yukon	Territoires du Nord-Ouest	Nunavut
Homme	0-6	-10,7	9,9	-4,5	2,5	1,7	3,6	-3,5	-17,3	-2,2	-14,3	-0,9	-11,4	-12,7
	7-17	-6,0	-4,6	-6,5	-7,2	4,0	-10,7	-0,9	-12,3	-4,2	-9,6			
	18-24	-35,5	-21,0	-27,4	-21,5	-2,9	-21,2	-30,4	-33,3	-11,5	-20,4	-28,2	-22,0	-16,0
	25-34	-29,6	-18,7	-27,2	-18,6	-18,1	-30,0	-20,2	-19,0	-16,4	-26,5			
	35-54	-11,4	-12,5	-3,6	-15,7	-9,5	-16,3	-14,6	-22,5	-23,2	-16,4			
	55-59	-20,2	-24,6	-29,4	-11,1	-13,2	-3,9	-26,1	-14,9	-20,0	-18,4			
	60-64	-20,7	-9,4	-9,2	-12,9	-22,0	2,0	-30,6	-5,9	-11,6	-14,2			
	65-69	-0,3	-3,6	-3,8	1,9	-16,3	11,2	-32,5	-0,2	-11,5	-19,6			
	70 +	-2,7	3,8	-19,5	-10,6	-2,4	-13,6	7,8	5,9	-10,1	-12,8			
	Total	**-15,5**	**-10,2**	**-12,7**	**-12,6**	**-7,9**	**-13,6**	**-14,0**	**-16,6**	**-14,4**	**-16,9**	**-21,7**	**-18,8**	**-14,6**
Femme	0-6	-10,3	14,3	0,5	9,9	6,3	-13,3	-7,7	-5,6	-10,6	-8,6	-20,4	-25,3	-16,8
	7-17	-9,8	-3,4	-4,0	-10,7	-5,4	-6,0	7,4	-19,8	-3,5	-15,1			
	18-24	-17,1	-20,5	-10,9	-11,5	-6,8	-17,6	-9,4	-19,3	-8,0	-26,6	-24,6	-15,4	-8,6
	25-34	-18,3	-12,5	-16,3	-17,9	-7,2	-16,9	-22,1	-24,2	-9,7	-27,0			
	35-54	-8,5	-5,0	-0,3	-6,6	-3,9	-12,0	-3,0	-15,4	-17,1	-14,4			
	55-59	-6,9	-12,4	-22,0	-10,3	-17,4	6,5	-22,0	-3,4	-17,9	-18,2			
	60-64	-8,1	0,7	-12,1	-5,4	-14,2	-1,0	-2,3	-1,7	-5,1	-10,6			
	65-69	-5,4	-21,1	-1,5	-8,7	11,9	-11,2	-18,8	-3,9	-25,5	-3,8			
	70 +	-13,0	-7,1	-1,0	-0,5	-8,3	-9,0	12,0	9,1	-11,4	-11,9			
	Total	**-11,1**	**-7,0**	**-6,0**	**-7,6**	**-5,3**	**-10,5**	**-4,9**	**-12,2**	**-11,9**	**-16,4**	**-23,7**	**-18,6**	**-12,1**
Total		**-13.3**	**-8,6**	**-9,3**	**-10,1**	**-6,6**	**-12,1**	**-9,4**	**-14,4**	**-13,1**	**-16,6**	**-22,7**	**-18,7**	**-13,4**

On observe un sous-dénombrement net pour chacune des provinces et chacun des territoires, les taux variant de 6,6 % à 22,7 %. L'ampleur du sous-dénombrement est plus importante pour les territoires. C'est au Québec que l'on retrouve le plus faible taux de sous-dénombrement (6,6 %). Toutefois, le taux plus faible au Québec est dû dans une certaine mesure à l'échantillon supplémentaire de cette province en 2003. En effet, lorsque l'on omet l'échantillon supplémentaire au Québec, le taux de sous-dénombrement net passe de 6,6 % à 8,8 % (donnée non présentée) pour cette province. On doit mentionner qu'un faible taux de sous-dénombrement global n'est toutefois pas garant d'une meilleure couverture. Par exemple, le taux de glissement général observé à l'Île-du-Prince-Édouard (-8,6 %) cache le pire cas de surdénombrement à l'échelle provinciale des groupes d'âge-sexe (14,3 % chez les filles de 0 à 6 ans). En revanche, bien que le taux de glissement général observé en Colombie-Britannique soit de -16,6%, cette province n'affiche que le douzième pire cas de sous-dénombrement (27,0 % chez les femmes de 25 à 34 ans).

À l'échelle provinciale, le taux de sous-dénombrement le plus élevé est observé chez les hommes de 18 à 24 ans à Terre-Neuve-et-Labrador (35,5 %). Le sous-dénombrement chez les hommes de 25 à 34 ans est plus important. En effet, pour toutes les provinces on observe un taux de sous-dénombrement supérieur à 16,0 %, ce qui explique le taux global de 24,2 % à l'échelle nationale (voir le Tableau 3.1). On remarque également que le schéma de variation des taux de glissement pour les groupes d'âge-sexe diffère sensiblement d'une province à l'autre.

Tableau 3.3
Taux de glissement pour les provinces et le Yukon[7] selon la taille de ménage

Province ou territoire	Taux de glissement			
	Ménages	Ménages d'une personne	Ménages de deux personnes	Ménages de trois personnes et plus
Canada[1]	-8,5	-2,2	-7,5	-13,2
Terre-Neuve-et-Labrador	-8,1	11,0	-5,1	-17,2
Île-du-Prince-Édouard	-8,3	-9,8	-3,3	-11,3
Nouvelle-Écosse	-6,7	0,6	-8,2	-9,8
Nouveau-Brunswick	-4,9	6,2	3,1	-17,6
Québec	-5,0	-3,8	-3,0	-8,0
Ontario	-9,6	-2,9	-8,6	-13,9
Manitoba	-5,7	5,5	-9,5	-10,5
Saskatchewan	-9,4	2,8	-8,0	-19,4
Alberta	-10,6	-5,7	-14,2	-10,5
Colombie-Britannique	-11,8	-0,3	-9,6	-21,5
Yukon	-14,9	-2,0	-12,7	-26,7

1. Exclut les Territoires du Nord-Ouest et le Nunavut.

On observe une sous-estimation du nombre de ménages de 8,5 % à l'échelle nationale. Ce taux de glissement est légèrement inférieur au taux de glissement pour les personnes qui est de -11,3 %.

À l'échelle provinciale et territoriale, il y a une variation importante du taux de glissement pour les ménages d'une personne. Le taux varie de -9,8 % à l'Île-du-Prince-Édouard jusqu'à 11,0 % pour Terre-Neuve-et-Labrador. Le même phénomène est observable pour les ménages de deux personnes mais avec une variation moindre. Pour les ménages de deux personnes, les taux de glissement varient de -14,2 % pour l'Alberta à 3,1 % pour le Nouveau-Brunswick. Pour les ménages de trois personnes et plus, les taux de glissement varient de -26,7 % pour le Yukon à -8,0 % au Québec.

7 Pour l'année de référence 2003, les poids de sondage n'ont pas été ajustés pour refléter les estimations post-censitaires du nombre de ménages aux Territoires du Nord-Ouest et au Nunavut (voir section 3.2).

Notons qu'à l'exception du Nouveau-Brunswick, on observe toujours un sous-dénombrement pour les catégories des ménages de deux personnes et trois personnes et plus. Soulignons que pour les ménages de trois personnes et plus, le sous-dénombrement est généralement supérieur à 10 %. Encore une fois, le taux plus faible au Québec (8,0 %) pour cette dernière catégorie est dû dans une certaine mesure à l'échantillon supplémentaire de cette province en 2003. Lorsque l'on omet l'échantillon supplémentaire au Québec, le taux de sous-dénombrement net de cette catégorie passe de 8,0 % à 10,3 % (donnée non présentée) pour cette province. À l'exception de l'Alberta, le sous-dénombrement le plus élevé est observé pour les ménages de trois personnes et plus.

3.2 L'ajustement au niveau de la population et des ménages

Afin de corriger le problème de représentativité illustré dans les tableaux 3.1 et 3.2 et réduire le biais qui en découle, on ajuste les données de l'enquête lors de la pondération en utilisant les estimations démographiques pour les groupes d'âge-sexe définis dans ces tableaux, et ce pour chaque province et territoire. Pour plus de détails sur la méthodologie de l'ajustement, voir la référence [1]. Cet ajustement réduit le biais mais ne l'élimine pas complètement si les caractéristiques des individus que l'on a omis de l'enquête diffèrent de celles des individus inclus pour un même groupe d'âge dans une province.

On notera également que l'efficacité de l'ajustement à partir des estimations démographiques dépend beaucoup de la qualité de ces estimations démographiques et de leur exactitude à bien représenter la population cible de l'enquête. Les estimations démographiques ne sont pas exemptes d'erreurs. Ce sont des estimations post-censitaires basées sur les comptes de population du recensement de 1996, ajustées pour le sous-dénombrement net et qui tiennent compte des récentes statistiques sur la migration, les naissances, la mortalité, etc. Ces estimations démographiques sont ajustées pour tenir compte de certaines exclusions spécifiques aux enquêtes auprès des ménages comme les personnes vivant en institutions. Conceptuellement, elles diffèrent légèrement de la population cible de l'EDM en incluant les personnes habitant les ménages collectifs qui ne sont pas des institutions, par exemple les membres de groupes vivant en communauté et les individus vivant de façon permanente dans les hôtels ou les maisons de chambres. Cependant, on considère cette différence négligeable puisque ces individus représentent moins de 0,4 % de la population canadienne.

Pour corriger le problème de représentativité de l'échantillon par rapport au nombre de ménages selon leur taille, illustré dans le tableau 3.3, on ajuste les données de l'enquête à l'aide de données auxiliaires. En ajustant les poids de l'EDM pour refléter les estimations post-censitaires du nombre de ménages selon la taille, on vise à compenser le biais qui découle d'une représentation inadéquate des ménages. Toutefois on n'éliminera pas nécessairement ce biais si les caractéristiques des ménages non interviewés (omis ou non-répondants) diffèrent de celles des ménages répondants pour une même taille de ménage. Comme dans le cas des estimations démographiques de population, l'efficacité de l'ajustement dépend de la qualité des données auxiliaires sur le nombre de ménages. À ce titre, les contrôles selon le nombre de ménages calculés pour l'EDM présentaient un bris dans la série des contrôles qui avaient été produits

jusqu'à ce jour pour les Territoires du Nord-Ouest et le Nunavut. Alors que les contrôles jusqu'en janvier 2001 étaient similaires aux données du recensement, ceux de janvier 2002 s'en écartaient. Afin de diminuer l'impact de cette brisure dans la série sur les données de l'EDM, certains changements avaient été apportés à la méthodologie utilisée pour la production des données auxiliaires sur le nombre de ménages dans ces deux territoires pour la pondération de l'EDM de 2001. Par ailleurs, dans les provinces et au Yukon aucun problème n'apparaît dans la série de contrôles basés sur le recensement de 1996. Quant à l'EDM de 2003, la brisure dans la série de contrôles selon le nombre de ménages existait toujours pour ces deux territoires. Notons que la nouvelle série de contrôle basée sur le recensement de 2001 est disponible et cette dernière série ne présente plus de bris pour ces deux territoires. Toutefois avant d'utiliser la nouvelle série basée sur le recensement de 2001, des évaluations doivent être faites pour déterminer l'impact des nouveaux contrôles sur les estimations de l'enquête. Pour toutes ces raisons et puisque les changements apportés en 2001 ne devaient être qu'une mesure temporaire, il a été décidé de ne pas utiliser les contrôles sur le nombre de ménages au Nunavut et aux Territoires du Nord-Ouest pour la pondération de l'EDM de 2003. Bien que les poids de sondage n'ont pas été ajustés pour tenir compte du nombre de ménages (basé sur le recensement de 1996) aux Territoires du Nord-Ouest et au Nunavut, les estimations du nombre total de ménages obtenues à l'aide des poids finaux sont similaires aux contrôles du nombre de ménages fondés sur le recensement de 2001 pour ces deux territoires. On obtient ainsi un surdénombrement net de 1,3 % aux Territoires du Nord-Ouest et un sous-dénombrement net de 4,0 % au Nunavut.

En plus des estimations démographiques quant aux groupes âge-sexe par province, trois autres ensembles de données auxiliaires sont utilisés pour ajuster les données d'enquêtes lors de la pondération en vue d'en améliorer la représentativité. Le premier ensemble de données est utilisé pour contrôler le nombre d'enfants et d'adultes dans certaines grandes villes. Le second est conçu pour contrôler le nombre de ménages monoparentaux et de couples avec enfants par province. Finalement, des comptes par grandes catégories de revenu en salaires et traitements sont utilisés lors de l'ajustement des poids afin d'assurer une certaine cohérence entre les distributions de revenu de l'EDM et celles provenant de sources externes.

4. Les erreurs de réponse

Les erreurs de réponse correspondent au manque d'exactitude des réponses aux questions. Elles peuvent être attribuables à différents facteurs parmi lesquels se retrouvent un questionnaire qui nécessite des améliorations, une mauvaise interprétation des questions par les intervieweurs ou les répondants ainsi que des erreurs dans les déclarations des répondants.

Dans l'EDM, les erreurs dans les déclarations des répondants peuvent survenir pour différentes raisons. Premièrement, il y a les erreurs de rappel qui se produisent lorsque le répondant oublie les dépenses effectuées durant la période de l'enquête (qui correspond à l'année civile) ou fournit une valeur erronée à cause de l'intervalle de temps écoulé entre le moment de l'achat et la date de

l'entrevue. Les erreurs de rappel sont probablement la source d'erreur de réponse la plus importante de l'enquête étant donné que la période de référence est longue (12 mois) et qu'une grande variété d'information est demandée.

Une des principales mesures utilisées pour minimiser l'erreur de rappel dans l'EDM est de calculer, pour chaque ménage, la différence entre les entrées d'argent (revenus et autres montants reçus par le ménage) et les déboursés (dépenses plus variation nette de l'actif et du passif). Lorsque la différence excède 10 % des entrées d'argent ou des déboursés, le montant le plus élevé étant retenu, les répondants sont contactés à nouveau pour obtenir des renseignements supplémentaires et tenter d'identifier les erreurs ou les omissions. On encourage également le répondant à consulter divers documents (factures, relevés bancaires,...) pour fournir des données plus exactes. Pour déterminer les dépenses pour de petits articles achetés à intervalles réguliers, les intervieweurs suggèrent généralement aux répondants d'estimer la fréquence des achats et le prix généralement payé pour dériver les dépenses sur une période de 12 mois.

Une seconde source d'erreur dans la déclaration des répondants est l'erreur télescopique qui consiste à inclure dans la période de référence des événements qui se sont produits avant ou après celle-ci. Dans l'EDM, on considère que le fait d'utiliser l'année civile est un bon repère pour le début de la période de référence. De plus, comme la période de référence est longue, l'impact de l'erreur télescopique est moins important.

Les réponses par procuration peuvent également contribuer à l'erreur de réponse. Le membre du ménage qui a effectué une dépense est généralement la personne qui peut la rapporter avec la meilleure précision. C'est sûrement le cas par exemple pour les achats personnels. Les dépenses rapportées par personne interposée sont plus susceptibles d'être entachées d'une erreur de réponse et ce type d'erreur risque d'affecter plus sérieusement certaines catégories de dépenses.

Parmi d'autres sources d'erreur de réponse, il ne faut pas oublier le degré de coopération du répondant. Il se peut que le répondant décide pour des raisons personnelles de ne pas mentionner certaines dépenses ou de déformer les faits.

Dans l'EDM, on considère également que le fardeau imposé au répondant, étant donné la longueur de l'entrevue et la grande variété d'articles à rapporter, ainsi que le rythme de l'entrevue peuvent entraîner la fatigue du répondant et avoir un impact sur la qualité des réponses obtenues. Le temps d'entrevue varie beaucoup d'un ménage à l'autre selon la taille du ménage, le revenu et plusieurs autres caractéristiques. Pour certains ménages, l'entrevue peut prendre plus de cinq heures.

Il convient de signaler que l'on a ajouté des questions à l'EDM de 2001. Entre autres, pour 2001 seulement, des questions supplémentaires à l'EDM ont été ajoutées pour que les données de l'enquête puissent servir à la pondération de l'Indice des prix à la consommation. Ce changement peut nuire aux comparaisons historiques à l'égard de certaines variables. Par exemple, on a ajouté des questions à la rubrique « Produits de soins personnels » afin de recueillir des

renseignements précis sur les produits de soins, le maquillage, les parfums, les désodorisants et les produits pour l'hygiène buccale. Ainsi, il se peut que les répondants aient donné un nombre accru de renseignements précis et que l'estimation à la hausse pour les « Produits de soins personnels » soit attribuable, du moins en partie, à la capacité accrue qu'ont les répondants de se souvenir de certains détails. L'effet des questions supplémentaires sur les estimations est difficile à quantifier. Cependant, en 2002 lorsque les questions additionnelles ont été enlevées, l'estimation pour les dépenses en soins personnels a diminué de nouveau.

Quoique l'on considère que les erreurs de réponses sont une source importante d'erreur dans une entrevue rétrospective, elles demeurent l'aspect lié à la qualité des données le plus difficile à mesurer. Il faut généralement entreprendre des études spéciales très coûteuses pour tenter de les mesurer. On tente de les réduire en implantant des techniques de sondage développées à cet effet.

5. Les erreurs de traitement

Des erreurs peuvent se produire lors de toutes les manipulations des données. Les principales étapes du traitement des données sont le codage des réponses, la saisie des données, la vérification, l'imputation des non-réponses partielles et la pondération. Dans l'EDM, différentes procédures sont appliquées à chacune des étapes afin de réduire au minimum les erreurs de traitement et les estimations de l'enquête sont comparées avec d'autres sources avant d'être publiées. Les erreurs qui peuvent découler des ajustements effectués lors de la pondération ont été décrites dans les sections 2 et 3. La présente section couvre principalement les autres types d'erreurs de traitement.

Le codage des réponses est nécessaire pour très peu de questions. Ce travail est effectué par l'intervieweur, puis vérifié par l'intervieweur principal. Avant 2001, la saisie des données était vérifiée à l'aide d'un système de vérification automatisé qui consistait à grouper les questionnaires par lots et à choisir, dans chacun de ces lots, un échantillon de questionnaires qui seraient saisis une seconde fois. Toutes les erreurs relevées étaient corrigées. Si le nombre d'erreurs dépassait un certain seuil, le lot complet était de nouveau soumis à la saisie. Contrairement aux années précédentes aucune procédure de vérification des questionnaires par lot n'a été utilisée depuis 2001, à la suite de l'introduction d'un nouveau système de saisie des données (BLAISE). Toutefois, des règles de vérifications ont été implantées dans ce système afin de pouvoir assurer la cohérence des informations saisies. Les résultats préliminaires d'une étude sur la saisie semblent démontrer que les taux d'erreurs de saisie avec le nouveau système sont similaires à ceux avec l'ancien système.

Une première étape de vérification automatisée des questionnaires est effectuée après que chacun d'eux ait été vérifié manuellement par l'intervieweur et l'intervieweur principal. On s'assure que certaines règles essentielles de cohérence entre les réponses rapportées sur le questionnaire sont respectées. On identifie également les situations inhabituelles qui pourraient justifier des corrections. Cette étape de vérification automatisée est effectuée dans les

bureaux régionaux de Statistique Canada, ce qui permet de communiquer avec les répondants lorsque des renseignements supplémentaires sont nécessaires pour résoudre des incohérences dans les réponses qu'ils ont fournies. Les problèmes identifiés au cours de cette vérification sont résolus par les membres des équipes de résolution des vérifications qui ont reçu une formation spéciale à cet égard. Par la suite, d'autres vérifications des données sont faites au bureau central et les réponses invalides sont corrigées.

Le traitement des données de l'EDM comprend également l'imputation de données pour la non-réponse partielle. Il y a non-réponse partielle lorsque le répondant refuse de répondre ou ne connaît pas la réponse à certaines questions particulières. Les données catégoriques peuvent prendre uniquement quelques valeurs (comme les questions pour lesquelles la réponse est oui ou non et les questions sur le type de logement habité) alors que les données continues peuvent prendre n'importe quelle valeur numérique (comme les revenus et les dépenses).

Les données sur le revenu et les dépenses sont imputées au moyen de la technique du plus proche voisin. L'imputation se fait sur un groupe de variables à la fois, ce groupe étant formé de sorte à tenir compte des relations entre ces variables. Un groupe correspond généralement à une section du questionnaire. Pour chaque groupe, les valeurs manquantes d'un receveur (un ménage qui a des données manquantes pour au moins une de ces variables) sont imputées à partir des données du plus semblable parmi tous les donneurs (les ménages qui n'ont aucune donnée manquante pour ces variables). Pour chaque receveur, on détermine le donneur le plus semblable comme étant celui qui a la valeur minimale pour une certaine fonction de distance. Cette fonction est basée sur des variables d'appariement choisies parce qu'elles sont corrélées avec les variables à imputer. Par exemple, le revenu total du ménage fait partie des variables d'appariement pour presque toutes les sections portant sur les dépenses. Dans le choix du donneur, on tient compte également du fait que le receveur doit satisfaire certaines règles de cohérence après l'imputation de ces données manquantes. Pour la plupart des sections, l'imputation est effectuée au niveau du ménage mais dans certains cas, par exemple pour le revenu et les dépenses en vêtements, l'imputation est effectuée au niveau de la personne car c'est à ce niveau que l'on collecte l'information pour ces variables.

Notons que depuis 2001, l'imputation des données sur le revenu et les dépenses est effectuée à l'aide du Système canadien de contrôle et d'imputation du recensement (SCANCIR) de Statistique Canada. Le nouveau système utilise une méthodologie quelque peu différente de celle du système utilisé auparavant. Ce système permet une meilleure utilisation des données catégoriques lors de la sélection du donneur. De plus, ce système permet à la fois l'imputation des données continues et des données catégoriques. Des tests ont été effectués avant l'introduction du système et les résultats obtenus étaient semblables à ceux obtenus avec l'ancien système. À compter de 2003, les données catégoriques, qu'on trouve principalement dans les sections sur les caractéristiques et l'équipement du logement, sont imputées à l'aide du SCANCIR. Les données catégoriques étaient imputées auparavant à l'aide d'une technique "hot deck" où un ménage donneur est choisi de façon aléatoire parmi un groupe de ménages répondants possédant des caractéristiques semblables.

Le biais des estimations causé par l'imputation de la non-réponse partielle est difficile à évaluer. Il dépend de la différence entre les répondants et les non-répondants ainsi que de la capacité de la méthode d'imputation à produire des estimations non biaisées. Toutefois, les taux d'imputation donnent une indication de l'importance des non-réponses partielles. Ils sont présentés dans la section suivante.

5.1 Proportion de ménages ou personnes nécessitant imputation, à l'échelle nationale, provinciale et territoriale

Une première indication de l'ampleur de la non-réponse partielle est la proportion de ménages nécessitant imputation et le nombre de variables imputées par ménage. Le questionnaire peut se diviser en deux grands groupes de variables, celles qui sont recueillies au niveau du ménage et celles collectées auprès des individus telles que le revenu et les dépenses en vêtements. Pour ces dernières catégories, il est important de noter que l'on accepte que le répondant fournisse seulement le revenu total ou les dépenses totales s'il est incapable de fournir la ventilation par source de revenu ou type de dépenses. Le niveau d'imputation pour les composantes du revenu et des dépenses vestimentaires est donc plus élevé mais n'affecte pas le revenu total, les dépenses vestimentaires totales ainsi que le total des dépenses.

Le pourcentage de ménages pour lesquels il a fallu imputer des dépenses de ménage (excluant les dépenses vestimentaires et les dépenses de la section sur l'impôts personnels, sécurité et dons en argent) est présenté dans la prochaine sous-section. Dans celle qui la suit, on présente le pourcentage de personnes pour lesquelles il a fallu imputer au moins une variable reliée aux dépenses vestimentaires, le pourcentage de personnes pour lesquelles au moins une variable de revenu a été imputée et le pourcentage de personnes pour lesquelles il a fallu imputer au moins une variable de la section sur l'impôts personnels, sécurité et dons en argent. Finalement dans la dernière sous-section on présente les résultats pour le pourcentage de ménages pour lesquels il a fallu imputer au moins une des variables catégoriques. À la suite de l'imputation des données par le système, certaines corrections peuvent s'avérer nécessaires, autant sur les variables imputées par le système que sur les autres, afin d'assurer la cohérence des données. Dans les faits, cette année, environ 1% des ménages ont été modifiés manuellement. Les résultats sont fournis tant à l'échelle nationale que provinciale et territoriale. Cela fournit une indication des provinces et territoires qui sont les plus affectées par l'imputation.

5.1.1 Imputation de dépenses du ménage par province et territoire

Le pourcentage de ménages utilisables pour lesquels il a fallu imputer au moins une variable de dépenses (excluant les dépenses vestimentaires et les dépenses de la section sur l'impôts personnels, sécurité et dons en argent) figure dans le tableau 5.1. Les ménages utilisables correspondent à tous les ménages demeurant dans des logements admissibles, à l'exception de ceux qui n'ont pu être contactés, qui ont refusé de participer à l'enquête, qui ont fourni des données incomplètes ou qui ne balançaient pas (voir définitions dans la section 2.1). Le tableau est réparti en fonction du nombre de variables qui ont été imputées (parmi les 229) pour un ménage.

Il importe de préciser que les paiements hypothécaires réguliers ainsi que les primes d'assurance hypothécaire sont inclus au titre des dépenses de logement et donc dans les dépenses totales. Depuis 2002, ces deux variables sont ajoutées au calcul des taux d'imputation présentés au Tableau 5.1. Ceci a pour effet d'augmenter le taux global d'imputation.

Tableau 5.1
Ménages qui nécessitent l'imputation de dépenses par province et territoire

Province ou territoire	Ménages (%) qui nécessitent l'imputation de **variables de dépenses**[1] (sauf pour les dépenses en vêtements et les dépenses de la section sur l'impôts personnels, sécurité et dons en argents)			
	Nombre de variables imputées (parmi 229)			
	1	**2**	**3 ou plus**	**Total**
Canada	**9,9**	**1,8**	**1,1**	**12,8**
Terre-Neuve-et-Labrador	15,5	2,0	0,7	18,2
Île-du-Prince-Édouard	16,0	1,5	0,0	17,6
Nouvelle-Écosse	13,2	2,5	1,8	17,5
Nouveau-Brunswick	8,4	1,2	0,7	10,3
Québec	5,8	0,5	0,2	6,6
Ontario	11,3	3,2	3,0	17,5
Manitoba	8,9	1,6	0,4	10,9
Saskatchewan	8,7	1,5	0,7	10,9
Alberta	9,3	1,3	0,7	11,3
Colombie-Britannique	9,9	3,2	2,5	15,7
Yukon	13,0	1,3	0,7	15,0
Territoires du Nord-Ouest	12,1	3,2	0,3	15,6
Nunavut	7,3	1,4	0,5	9,2

1. Inclut les paiements hypothécaires réguliers et les primes d'assurance hypothécaire.

Le tableau 5.1 montre qu'il a fallu imputer des dépenses (mise à part la section sur les vêtements et la section sur l'impôts personnels, sécurité et dons en argent) pour 12,8 % des ménages à l'échelle nationale, mais pour près de 77 % d'entre eux, seulement une variable a été imputée. Le taux global d'imputation en excluant les paiements hypothécaires réguliers et les primes d'assurance hypothécaire est de 8,3 % (donnée non présentée), ce qui est comparable aux taux obtenus les années précédentes. À elle seule, la variable représentant les primes d'assurance hypothécaire nécessite une imputation pour 5,3 % des ménages (soit 15,6 % des ménages lorsque l'on se restreint aux ménages ayant déclaré des hypothèques sur les logements dont ils étaient propriétaires et occupants).

Il y a très peu de ménages à l'échelle nationale qui ont eu plus d'une variable imputée (2,9 %). Les provinces ou territoires pour lesquels on observe les plus basses proportions de ménages ayant requis l'imputation d'au moins une variable

de dépense sont le Québec (6,6 %) et le Nunavut (9,2 %). Seuls cette province et ce territoire affichent un taux global d'imputation inférieur à 10 %. On retrouve les taux les plus élevés à Terre-Neuve-et-Labrador (18,2 %), à l'Île-du-Prince-Édouard (17,6 %), en Nouvelle-Écosse (17,5 %) et en Ontario (17,5 %). C'est en Ontario et en Colombie-Britannique où l'on trouve le pourcentage le plus élevé de ménages pour lesquels il a fallu imputer plus d'une variable de dépenses. Dans ces deux provinces, on a imputé au moins deux variables de dépenses pour plus du tiers des ménages qui nécessitaient une imputation. Le faible pourcentage (en particulier si on exclut les paiements hypothécaires réguliers et les primes d'assurance hypothécaire) de ménages pour lesquels des variables doivent être imputées, combiné à un nombre généralement peu élevé de variables à imputer lorsque l'imputation est nécessaire, suggère que l'impact des valeurs imputées sur les estimations ne devrait pas être trop élevé.

5.1.2 Imputation des dépenses des personnes et du revenu par province et territoire

Étant donné qu'une partie des répondants fournissent uniquement le total pour les variables de dépenses en vêtements et les variables de revenu, celles-ci sont imputées, au niveau des individus, en deux étapes. Les individus pour lesquels il faut imputer seulement quelques composantes sont imputés en premier lieu, suivis par ceux pour lesquels seulement les totaux sont disponibles et qui nécessitent l'imputation de toutes les composantes. (Voir la référence [1] pour une description plus détaillée de ce processus).

Le pourcentage d'individus utilisables (personnes membres des ménages utilisables) pour lesquels il a fallu imputer au moins une variable de revenu est indiqué par province et territoire dans le tableau 5.2. On y retrouve le pourcentage de personnes pour lesquelles exactement une variable a été imputée, ceux dont deux variables ou plus (mais pas toutes) ont été imputées et le pourcentage des personnes pour lesquelles seul le revenu total était disponible, nécessitant ainsi l'imputation de toutes les composantes. Le pourcentage total de personnes pour lesquelles une forme d'imputation de revenu a été effectuée est également donné. L'avant dernière colonne du tableau 5.2 contient ce même pourcentage total de personnes pour lesquelles une forme d'imputation a été effectuée, mais pour les dépenses en vêtements. La dernière colonne contient le pourcentage total de personnes pour les lesquelles une forme d'imputation a été effectuée pour les variables de la section du questionnaire portant sur l'impôts personnels, sécurité et dons en argent.

Il importe de préciser que seuls les membres du ménage âgés de 15 ans et plus au 31 décembre de l'année de référence doivent répondre aux questions portant sur le revenu personnel et celles de la section sur les impôts personnels, sécurité et dons en argent. Par conséquent, cette année le pourcentage de personnes qui nécessitent l'imputation de variables de revenu ou pour celles de la section sur l'impôts personnels, sécurité et dons en argent a été calculé en se restreignant aux personnes de 15 et plus et non sur l'ensemble des personnes comme pour les années précédentes. Ceci a pour effet d'augmenter légèrement le taux d'imputation pour ces variables. Tout comme pour les années précédentes, le pourcentage de personnes qui nécessitent l'imputation de dépenses vestimentaires est

calculé sur l'ensemble des personnes, puisque tous les membres d'un ménage doivent répondre aux questions portant sur ce type de dépenses.

Tableau 5.2
Personnes qui nécessitent l'imputation du revenu, personnes qui nécessitent l'imputation de dépenses en vêtements et personnes qui nécessitent l'imputation de variables de la section sur l'impôts personnels, sécurité et dons en argent par province et territoire

Province ou territoire	Pourcentage de personnes qui nécessitent l'imputation de **variables de revenu**				Pourcentage de personnes qui nécessitent l'imputation d'au moins une des 11 variables de dépenses vestimentaires	Pourcentage de personnes qui nécessitent l'imputation d'au moins une des 15 variables de la section sur l'impôts personnels, sécurité et dons en argent
	1 variable imputée	2 variables imputées ou plus (pas toutes)	Toutes les variables imputées (revenu total connu)	**Total** (toute forme d'imputation)		
Canada	**1,0**	**0,3**	**3,3**	**4,7**	**18,6**	**3,2**
T.-N.-L.	0,5	0,1	2,9	3,7	7,4	1,9
Î.-P.-É.	0,1	0,2	8,1	8,6	12,5	1,0
N.-É.	0,6	0,1	3,9	4,7	15,2	5,1
N.-B.	0,5	0,2	6,3	7,1	14,8	2,4
Qc	0,6	0,1	1,9	2,6	19,9	1,2
On.	2,3	0,7	3,2	6,2	16,3	6,8
Man.	1,6	0,4	2,1	4,2	19,1	2,4
Sask.	0,4	0,6	3,0	4,2	24,5	3,0
Alb.	0,3	0,3	3,1	3,8	20,9	2,3
C.-B.	2,4	0,4	4,1	7,0	20,0	5,6
Yn	0,5	0,4	4,4	5,3	40,9	4,2
T.N.-O.	0,7	0,0	1,3	2,0	34,1	1,3
Nt	0,0	0,0	0,8	0,8	26,3	0,8

À partir de ces résultats, on constate qu'il y a près de 5 % des personnes des ménages utilisables pour lesquelles il a fallu imputer au moins une variable de revenu. Pour 70 % d'entre elles, le revenu total était disponible mais toutes les composantes ont dû être imputées. Pour une très grande partie des autres personnes qui ont nécessité imputation, seulement une composante de revenu (une variable) a été imputée. Rappelons que cette année les taux d'imputation pour les variables de revenu sont calculés en se restreignant aux personnes de 15 ans et plus. Le taux global d'imputation calculé sur l'ensemble des personnes est de 3,8 % (donnée non présentée), ce qui se compare au taux de 4,1 % obtenu en 2002. À l'échelle provinciale et territoriale, le pourcentage de personnes nécessitant l'imputation d'au moins une variable de revenu varie entre un

minimum de 0,8 % pour le Nunavut et un maximum de 8,6 % pour l'Île-du-Prince-Édouard. On observe un taux d'imputation plus élevé à l'Île-du-Prince-Édouard (8,6 %), au Nouveau-Brunswick (7,1 %), en Colombie-Britannique (7,0 %) et en Ontario (6,2 %). Pour l'Île-du-Prince-Édouard et le Nouveau-Brunswick, la majorité des cas à imputer correspond à la situation où le total du revenu est fourni par le répondant mais les toutes composantes doivent être imputées. Pour l'Ontario et la Colombie-Britannique, l'imputation se divise principalement entre le cas où il n'y a qu'une seule composante à imputer et le cas où total du revenu est fourni par le répondant mais toutes les composantes doivent être imputées.

Dans l'avant dernière colonne du tableau, on constate qu'environ 19 % des personnes ont nécessité une imputation pour au moins une des variables de dépenses vestimentaires. Les taux provinciaux et territoriaux s'échelonnent de 7,4 % pour Terre-Neuve-et-Labrador à 40,9 % au Yukon. Presque toutes ces personnes ont fourni le total de leurs dépenses vestimentaires, mais il a fallu imputer les composantes. Terre-Neuve-et-Labrador est la seule province où le taux d'imputation est inférieur à 10 %. On observe également que ces taux sont plus faibles dans les provinces de l'Atlantique et à l'opposé, plus élevés dans les territoires que pour les autres provinces. Le niveau élevé d'imputation effectuée sur les composantes des dépenses vestimentaires implique que les estimations de ces composantes pourraient être grandement affectées par l'imputation, alors que l'effet sur les estimations du total sera négligeable.

Dans la dernière colonne du tableau, on constate qu'environ 3 % des personnes ont nécessité une imputation pour au moins une des variables de la section sur l'impôts personnels, sécurité et dons en argent. Rappelons que cette année le taux d'imputation pour les variables de cette section est calculé en se restreignant aux personnes de 15 ans et plus. Le taux global d'imputation calculé sur l'ensemble des personnes est de 2,6 % (donnée non présentée), ce qui est identique au taux obtenu en 2002. À l'échelle provinciale et territoriale, ce pourcentage est également peu élevé, variant entre un minimum de 0,8 % au Nunavut et un maximum de 6,8 % pour l'Ontario. Seules les provinces de la Nouvelle-Écosse, de l'Ontario et de la Colombie-Britannique affichent un taux supérieur à 5 %. Dans ces trois provinces, le taux d'imputation plus élevé est dû à la variable représentant l'impôt personnel sur le revenu de 2003 qui nécessite en proportion plus d'imputation que pour les autres provinces et territoires.

5.1.3 Imputation des variables catégoriques par province et territoire

Le pourcentage de ménages utilisables pour lesquels il a fallu imputer au moins une variable catégorique figure dans le tableau 5.3. Le tableau est réparti en fonction du nombre de variables qui ont été imputées (parmi les 56) pour un ménage. Les variables catégoriques qui sont imputées se trouvent aux sections suivantes du questionnaire: Caractéristiques du logements (à l'exception de la variable genre de logement); Équipement associé au logement; Mode d'occupation du logement (à l'exception des variables se rapportant au changement dans le mode d'occupation durant l'année de référence); Tabac et dépenses diverses, pour les variables se rapportant aux achats par le biais de vente directe (questions pour lesquelles la réponse est oui ou non). Il est à noter que les autres variables catégoriques du questionnaire telles que celles se rapportant à la composition du ménage ou encore aux divers branchements du

questionnaire sont vérifiées et validées par les spécialistes du sujet de la Division de la statistique du revenu. Par conséquent, ces dernières variables ne sont pas imputées au moyen de la technique du plus proche voisin.

Tableau 5.3
Ménages qui nécessitent l'imputation de variables catégoriques par province et territoire

Province ou territoire	Ménages (%) qui nécessitent l'imputation de variables catégoriques			
	Nombre de variables imputées (parmi 56)			
	1	2	3 ou plus	Total
Canada	**4,7**	**0,6**	**1,2**	**6,4**
Terre-Neuve-et-Labrador	3,1	0,1	0,9	4,2
Île-du-Prince-Édouard	2,1	0,3	0,3	2,8
Nouvelle-Écosse	3,0	0,2	0,7	3,9
Nouveau-Brunswick	2,5	0,2	0,8	3,5
Québec	3,5	0,5	0,6	4,6
Ontario	6,5	1,0	2,4	9,9
Manitoba	4,7	0,6	1,5	6,8
Saskatchewan	7,5	1,3	1,9	10,7
Alberta	5,8	0,2	1,0	7,0
Colombie-Britannique	6,7	1,0	2,1	9,8
Yukon	6,2	0,3	1,6	8,1
Territoires du Nord-Ouest	3,5	0,3	0,3	4,1
Nunavut	2,8	0,9	0,5	4,1

Le tableau 5.3 montre qu'à l'échelle nationale, il a fallu imputer au moins une variable catégorique se rapportant aux caractéristiques du logements et équipement associé au logement, au mode d'occupation du logement et aux achats par le biais de vente directe pour 6,4 % des ménages. Toutefois, pour près de 75 % d'entre eux seulement une variable a été imputée. Les provinces ou territoires pour lesquels on observe les plus basses proportions de ménages ayant requis l'imputation d'au moins une variable catégorique sont l'Île-du-Prince-Édouard (2,8 %), le Nouveau-Brunswick (3,5 %) et la Nouvelle-Écosse (3,9 %). On retrouve les taux les plus élevés en Saskatchewan (10,7 %), en Ontario (9,9 %) et en Colombie-Britannique (9,8 %).

Références

[1] Tremblay J. et Arsenault, S. 2001. *La méthodologie de l'Enquête sur les dépenses des ménages.* N° 62F0026MIF2001003 au catalogue. Ottawa. Division des méthodes d'enquêtes auprès des ménages, Statistique Canada.

[2] Rao, J.N.K., Wu, C.F.J. et Yue K. 1992. « Quelques travaux récents sur les méthodes de rééchantillonnage applicables aux enquêtes complexes », *Techniques d'enquête*, 18(2), p.225-234 (Statistique Canada, N° 12-001 au catalogue).

[3] Statistique Canada, Division de la statistique de revenue. 2003. *Guide de l'utilisateur — Enquête sur les dépenses des ménages.* N° 62F0026MIF2004003 au catalogue. Ottawa.

[4] Statistique Canada, Division de la statistique de revenue. 2003. *Les habitudes de dépenses au Canada.* N° 62-202 au catalogue. Ottawa.

[5] Statistique Canada, Division des méthodes d'enquêtes auprès des ménages. 2003. *Enquête sur la population active, Rapport sur les opérations.* Enquête 200312. Ottawa.

[6] Lapierre, B., Nadeau, C., Tremblay, J. et Gaudet, J. 2004. « Amélioration de la qualité des estimations pour une population à faible revenu : utilisation d'une base duale à l'enquête sur les dépenses des ménages », Recueil du Symposium 2004 de Statistique Canada (à paraître).

Annexe A

Notation algébrique

1. Ajustement pour la non-réponse

Le sous-poids (c-à-d. le poids de sondage ajusté pour la non-réponse) d'un ménage k, noté w_k^{NR} , est

$$w_k^{NR} = \pi_k^{-1} * \frac{1}{taux_g} \quad avec \quad taux_g = \frac{\sum_{k \in s_{g,r}} \pi_k^{-1}}{\sum_{k \in s_{g,r}} \pi_k^{-1} + \sum_{k \in s_{g,nr}} \pi_k^{-1}}$$

où

$s_{g,r}$ est l'ensemble des ménages répondants dans le groupe de non-réponse g,

$s_{g,nr}$ est l'ensemble des ménages non-répondants (refus, non-contacts, données inutilisables) dans le groupe de non-réponse g, et

π_k^{-1} est le poids de sondage attribué au ménage k.

2. Calcul du taux de glissement

Le taux de glissement pour un groupe de contrôle c, noté $taux_c$, est,

$$taux_c = 100 * \frac{\left(\sum_{k \in s_{c,r}} w_k^{NR}\right) - t_c}{t_c}$$

où

$s_{c,r}$ est l'ensemble des ménages répondants dans le groupe de contrôle c,

w_k^{NR} est le sous-poids du ménage k, et

t_c est le total de la donnée auxiliaire pour le groupe de contrôle c.